

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2021

Bc. Markéta Boudová



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY  
A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE SKRYTÝCH P VLN POMOCÍ METOD  
HLUBOKÉHO UČENÍ

SEGMENTATION OF HIDDEN P WAVES USING DEEP LEARNING METHODS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Markéta Boudová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jakub Hejč

BRNO 2021

# Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

**Studentka:** Bc. Markéta Boudová

**ID:** 195183

**Ročník:** 2

**Akademický rok:** 2020/21

**NÁZEV TÉMATU:**

## Segmentace skrytých P vln pomocí metod hlubokého učení

### POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami hlubokého učení pro zpracování signálů. 2) Vytvořte literární rešerši se zaměřením na konvoluční neuronové sítě a obecné principy hlubokého učení. 3) Prostudujte dostupná elektrokardiografická data a v prostředí Python navrhnete a implementujete pipe-line pro jejich předzpracování. 4) Vyberte a implementujte vhodnou CNN architekturu pro segmentaci P vln. Úspěšnost modelu otestujte a statisticky vyhodnoťte pomocí vhodných metrik. 5) Proveďte modifikaci a optimalizaci architektury pro segmentaci jednosvodových a vícəsvodových EKG záznamů s cílem minimalizovat komplexitu modelu při zachování kvality segmentace. 6) Statisticky vyhodnoťte a diskutujte všechny dosažené výsledky.

### DOPORUČENÁ LITERATURA:

- [1] R. He et al., "Automatic Cardiac Arrhythmia Classification Using Combination of Deep Residual Network and Bidirectional LSTM," in IEEE Access, vol. 7, pp. 102119-102135, 2019, doi: 10.1109/ACCESS.2019.2931500.
- [2] Qihang Yao, Ruxin Wang, Xiaomao Fan, Jikui Liu, Ye Li, Multi-class Arrhythmia detection from 12-lead varied-length ECG using Attention-based Time-Incremental Convolutional Neural Network, Information Fusion, Vol. 53, 2020, Pages 174-182, ISSN 1566-2535, <https://doi.org/10.1016/j.inffus.2019.06.024>.
- [3] Van Steenkiste, G., van Loon, G. & Crevecoeur, G. Transfer Learning in ECG Classification from Human to Horse Using a Novel Parallel Neural Network Architecture. Sci Rep 10, 186 (2020), <https://doi.org/10.1038/s41598-019-57025-2>.

**Termín zadání:** 8.2.2021

**Termín odevzdání:** 21.5.2021

**Vedoucí práce:** Ing. Jakub Hejč

**prof. Ing. Ivo Provazník, Ph.D.**  
předseda rady studijního programu

### UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## **Abstrakt**

Cílem této diplomové práce je detekce P vlny v EKG záznamech. Úvod teoretické části se zabývá fyziologií srdce. V druhé části jsou vysvětleny základní principy hlubokého učení. V praktické části je v programovacím jazyce Python provedeno předzpracování EKG záznamů a naimplementována neuronová síť U-Net. Následně je provedena optimalizace architektury za účelem snížení komplexity modelu. V závěru práce je vyhodnocena úspěšnost sítě při segmentaci P vln.

## **Klíčová slova**

EKG signál, P vlna, hluboké učení, U-Net

## **Abstract**

The aim of this thesis is segmentation of P waves in ECG signals. The theoretical part of the thesis describes the physiology of the heart and the basics of deep learning methods. Preprocessing of the signals is performed and neural network U-Net is implemented in the Python software environment in the practical part. Afterwards, optimization of network architecture is performed in order to reduce model complexity. Lastly the success rate of the model is evaluated.

## **Keywords**

ECG signal, P wave, deep learning, U-Net

## **Bibliografická citace**

*BOUDOVÁ, Markéta. Segmentace skrytých P vln pomocí metod hlubokého učení [online]. Brno, 2021 [cit. 2021-05-09]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/134415>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Jakub Hejč.*

# Prohlášení autora o původnosti díla

<b>Jméno a příjmení studenta:</b>	<i>Bc. Markéta Boudová</i>
<b>VUT ID studenta:</b>	<i>195183</i>
<b>Typ práce:</b>	<i>Diplomová práce</i>
<b>Akademický rok:</b>	<i>2020/21</i>
<b>Téma závěrečné práce:</b>	<i>Segmentace skrytých <math>P</math> vln pomocí metod hlubokého učení</i>

Prohlašuji, že svou závěrečnou práci jsem vypracovala samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: 21. května 2021

-----  
podpis autora

## **Poděkování**

Tímto bych chtěla poděkovat vedoucímu diplomové práce Ing. Jakubovi Hejčovi za odborné vedení, konzultace a cenné rady při zpracování této práce.

V Brně dne: 21. května 2021

-----  
podpis autora





# Obsah

<b>1. SRDCE A EKG .....</b>	<b>12</b>
1.1 PŘEVODNÍ SYSTÉM SRDEČNÍ.....	12
1.2 ELEKTROKARDIOGRAM .....	13
1.3 EKG KŘIVKA.....	13
<b>2. NEURONOVÉ SÍTĚ .....</b>	<b>16</b>
2.1 NEURON .....	16
2.2 JEDNODUCHÁ NEURONOVÁ SÍŤ .....	18
2.3 HYPERPARAMETRY SÍTĚ .....	18
2.4 PŘENOSOVÁ AKTIVAČNÍ FUNKCE .....	20
2.5 PRINCIP UČENÍ.....	21
2.6 KRITERIÁLNÍ FUNKCE.....	21
2.7 OPTIMALIZACE .....	23
2.8 REGULARIZACE VAH .....	24
2.9 KONVOLUČNÍ NEURONOVÉ SÍTĚ .....	24
2.9.1 Konvoluční vrstva .....	24
2.9.2 Poolingová vrstva .....	25
2.9.3 BatchNorm vrstva .....	26
2.9.4 DropOut vrstva .....	26
2.10 REKURENTNÍ NEURONOVÉ SÍTĚ .....	26
<b>3. METRIKY HODNOCENÍ KVALITY MODELU .....</b>	<b>29</b>
<b>4. POUŽITÁ DATA .....</b>	<b>31</b>
<b>5. NAVRŽENÝ PROGRAM .....</b>	<b>34</b>
5.1 PŘEDZPRACOVÁNÍ DAT.....	34
5.1.1 Podvzorkování.....	35
5.1.2 Rozdělení dat do trénovací, validační a testovací množiny.....	36
5.1.3 Augmentace trénovací množiny.....	36
5.1.4 Vytvoření datasetů a dataloaderů .....	38
5.2 ARCHITEKTURA NAVRŽENÉ NEURONOVÉ SÍTĚ .....	40
5.2.1 Modifikace sítě U-Net .....	41
5.3 TRÉNOVÁNÍ MODELU .....	44
5.3.1 Výsledky pro intrakardiální signály.....	44
5.3.2 Výsledky pro 12svodové EKG .....	46
<b>6. VÝSLEDKY.....</b>	<b>50</b>
6.1.1 Zhodnocení kvality segmentace.....	54
<b>7. ZÁVĚR.....</b>	<b>66</b>

# SEZNAM OBRÁZKŮ

Obrázek 1 - Normální průběh EKG s uvedenou délkou jednotlivých intervalů [ms] (převzato z [6]) .....	14
Obrázek 2 - Fibrilace síní (svod I). P vlna není přítomna (převzato z [1]) .....	15
Obrázek 3 - Biologický neuron (převzato z [12]) .....	16
Obrázek 4 - Model neuronu (převzato z [11]) .....	17
Obrázek 5 - Plně propojená dopředná neuronová síť (převzato a upraveno z [10]) .....	18
Obrázek 6 – Nalezení globálního minima při příliš malém kroku učení (převzato z [10]).....	19
Obrázek 7 - Příliš velký krok učení, vlevo: u konvexní účelové funkce, vpravo: u složitější účelové funkce (převzato z [10]) .....	19
Obrázek 8 - Přenosová aktivační funkce. Shora skoková funkce, po částech lineární funkce, logistická sigmoida (převzato a upraveno z [11]).....	20
Obrázek 9 - Přenosová aktivační funkce. Shora hyperbolický tangent, ReLU, leaky ReLU (převzato a upraveno z [15]) .....	20
Obrázek 10 – Princip metody gradientního sestupu (převzato a upraveno z [18]) .....	23
Obrázek 11 – Konvoluční vrstva (převzato a upraveno z [21]) .....	25
Obrázek 12 – Max pooling s oknem 2x2 a krokem 2 (převzato z [21]).....	26
Obrázek 13 - Princip DroupOut vrstvy. Vlevo: před, vpravo: po vypnutí části neuronů (převzato a upraveno z [10]) .....	26
Obrázek 14 - Buňka LSTM sítě. Převzato z [10], upraveno. ....	28
Obrázek 15 – Srovnání povrchového a intrakardiálního záznamu EKG. Nahoře: EKG záznamy, dole: anotované P vlny. ....	32
Obrázek 16 - Blokové schéma předzpracování.....	35
Obrázek 17 - Původní EKG signál a signál po decimaci .....	36
Obrázek 18 - Signál před a po zašumění.....	37
Obrázek 19 - Signál před a po oříznutí a roztahení v y-ové ose. Červené okno znázorňuje vybraný úsek. ....	38
Obrázek 20 – EKG signál a jeho anotace doplněny hodnotami -1 na délku nejdelšího signálu v dávce.....	39
Obrázek 21 - Základní zapojení sítě U-Net (převzato z [27]).....	41
Obrázek 22 - U-net pro segmentaci EKG, převzato z [24]. ....	42
Obrázek 23-Naimplementovaná neuronová síť. ....	43
Obrázek 24 - Průběh kritériální funkce během učení na trénovací a validační množině. ....	44
Obrázek 25 - Přesnost segmentace během učení na trénovací a validační množině pro intrakardiální data. ....	45
Obrázek 26 - Průběh F1 skóre během učení na trénovací a validační množině pro intrakardiální data.....	45
Obrázek 27 - Průběh f1 skóre pro validační množinu před a po augmentaci.....	46
Obrázek 28 - Průběh kritériální funkce pro různá nastavení kroku učení. ....	47
Obrázek 29 - Průběh přesnosti pro různá nastavení parametru Batch size. ....	48
Obrázek 30 - Průběh přesnosti pro trénovací a validační množinu.....	50
Obrázek 31 - Průběh f1 skóre pro trénovací a validační množinu. ....	51
Obrázek 32 - Výsledek pro jiné rozzaření signálů do množin. Shora: diagnózy signálů v testovací množině, matice záměn, f1 skóre, přesnost pro testovací množinu.....	52
Obrázek 33 - Průběh f1 skóre pro trénovací a validační množinu. ....	53
Obrázek 34 - Průběh f1 skóre pro trénovací a validační množinu. ....	54
Obrázek 35 - Porovnání anotace a výstupu neuronové sítě pro jednu P vlnu. ....	55
Obrázek 36 - Porovnání anotace a výstupu neuronové sítě. Shora: EKG signál, anotace P vln, výstup neuronové sítě. ....	55
Obrázek 37 - Porovnání anotace a výstupu neuronové sítě. ....	56
Obrázek 38 - Porovnání anotace a výstupu neuronové sítě. ....	57

Obrázek 39 - Porovnání anotace a výstupu neuronové sítě. Dole přiblížení na PVC. ....	58
Obrázek 40 - Porovnání anotace a výstupu neuronové sítě. Dole v přiblížení.....	59
Obrázek 41 - Porovnání anotace a výstupu neuronové sítě. Dole v přiblížení.....	60
Obrázek 42 - Porovnání anotace a výstupu neuronové sítě. Dole přiblížení na FIS. ....	61
Obrázek 43 - Porovnání anotace a výstupu neuronové sítě. ....	62
Obrázek 44 - Porovnání anotace a výstupu optimalizované neuronové sítě.....	63
Obrázek 45 - Porovnání anotace a výstupu optimalizované neuronové sítě.....	63
Obrázek 46 - Porovnání anotace a výstupu optimalizované neuronové sítě.....	64
Obrázek 47 - Porovnání anotace a výstupu optimalizované neuronové sítě.....	65

## SEZNAM TABULEK

Tabulka 1 – Přehled stanovených diagnóz u EKG záznamů .....	33
Tabulka 2 - Použité knihovny. ....	34
Tabulka 3 - Parametry vrstev sítě .....	43
Tabulka 4 - Matice záměn pro trénovací, validační a tstovací množinu. ....	51
Tabulka 5 – Optimalizace architektury .....	52

# ÚVOD

Mezi nejčastější příčiny úmrtí v dnešní době patří komplikace spojené s kardiovaskulárními onemocněními. Elektrokardiografie je vyšetřovací metoda, pomocí které získáme informace o elektrické aktivitě srdce. Charakteristické vlny a kmity v EKG křivce jsou pak hlavním předmětem analýzy pro diagnostiku srdečních onemocnění. [1]

Analýzu EKG provádí specializovaný lékař. V několika posledních letech je však snaha vytvářet programy pro automatickou segmentaci a analýzu EKG křivek. Automatická analýza EKG křivek není jednoduchým úkolem. Například detekce P vlny pro její malou amplitudu v EKG křivce, která navíc obsahuje artefakty a rušení vzniklá při snímání, může být velmi obtížná.

Tato diplomová práce se zabývá detekcí P vln v EKG signálech. V úvodu teoretické části je popsána elektrofyziologie srdce a EKG křivka. V druhé části se práce zabývá základními principy hlubokého učení. V praktické části jsou v programovacím jazyku Python EKG záznamy předzpracovány. K příslušným EKG křivkám byly pomocí dostupných anotací vytvořeny binární reprezentace P vln. Neuronová síť U-Net byla implementována a vhodně modifikována pro zpracování EKG záznamů. Následně byla provedena optimalizace architektury za účelem snížení complexity modelu. V závěru práce byla úspěšnost implementovaného modelu otestována pomocí několika metrik.

# 1. SRDCE A EKG

Srdce je svalový orgán, který má za úkol pohánět krev cévami a umožnit tak výměnu látek a výživu tkání v lidském těle. Má tvar kužele a podélnou přepážkou je rozděleno na dvě poloviny. Každá polovina se skládá ze síně a komory. Nejmhutnější vrstvu svaloviny zaujímá levá komora, která vypuzuje krev do aortálního oběhu. Otvor mezi pravou síní a komorou je opatřen trojcípou chlopní. Do pravé síně krev přitéká horní a dolní dutou žílou, plicní kmen pak krev z pravé komory odvádí do plicní tepny. Otvor mezi pravou komorou a plicním kmenem je zaopatřen poloměsíčitou chlopní. Okysličená krev vstupuje do levé síně plicními žilami. Mezi levou síní a levou komorou se nachází dvojcípá chlopeň. Z levé komory je pak krev odváděna do velkého oběhu pomocí nejmhutnější tepny aorty. Toto vyústění je opatřeno poloměsíčitou chlopní.[1][2][8]

Srdeční stěnu tvoří endokard, myokard a epikard. Endokard vystýlá dutiny srdce, myokard je srdeční svalovina a epikard je vazivová vrstva, která kryje myokard. Na epikard pak navazuje osrdečník. Prostor mezi těmito dvěma vrstvami je vyplněn tekutinou pro snížení tření při stahování a roztahování srdečního svalu.[1][8]

Elektrická aktiva srdce je zajišťována srdečními buňkami neboli kardiomyocyty. Kardiomyocyty jsou krátké, rozvětvené buňky, které mají schopnost vytvářet vzruchy. Kardiomyocyty jsou navzájem propojeny vodivými spoji, což umožňuje rychlé přenášení vzruchu z jedné buňky na druhou. Pomocí převodního systému srdečního se elektrické vzruchy šíří po srdeční svalovině a dochází tak ke kontrakci myokardu. [1][8]

## 1.1 Převodní systém srdeční

Převodní systém srdeční je soubor specializovaných buněk, které vytvářejí a vedou elektrické vzruchy. Skládá se z SA uzlu, AV uzlu, Hisova svazku, levého a pravého Tawarova raménka a Purkyňových vláken. SA uzel je tzv. primární pacemaker. Místo, kde při fyziologických podmínkách vzniká vzruch. SA uzel má totiž schopnost spontánní depolarizace, kdy díky toku iontů skrz plazmatickou membránu buněk dochází ke změně napětí na membráně. Při překročení prahové hodnoty vzniká akční potenciál, který se šíří po myokardu síní až k AV uzlu. [1][2][8]

AV uzel se označuje jako sekundární pacemaker. Za fyziologických podmínek je aktivita AV uzlu zastíňována, neboť frekvence SA uzlu je rychlejší. Pokud však funkce SA uzlu není správná (např. generované impulzy jsou podprahové nebo mají nedostatečnou frekvenci), pak AV uzel přebírá roli pacemakeru. V AV uzlu dochází k zpomalení vedení akčního potenciálu za účelem správného plnění komor. Následně se vzruch šíří Hisovým svazkem, což je jediné vodivé propojení mezi síněmi a komorami. Na Hisův svazek navazuje pravé a levé Tawarovo raménko, které se dále dělí na

Purkyňova vlákna, jež jsou elektricky napojena na myokard komor. Srdce je tak elektricky drážděno od jeho hrotu směrem k jeho bázi. [1][2][3]

## 1.2 Elektrokardiogram


Elektrokardiografie je vyšetřovací metoda, která umožňuje měřit elektrickou aktivitu srdce. Přiloženými sadami elektrod na lidskou kůži se zaznamenávají změny elektrického napětí, které jsou projevem srdeční aktivity. Výsledkem je elektrokardiogram (EKG), jenž graficky znázorňuje činnost srdce. Umožňuje tak získat informace o tepové frekvenci, srdečním rytmu a původu vzruchů. Svody EKG můžeme rozdělit na unipolární a bipolární. U unipolárních svodů měříme napětí mezi měřicí a referenční elektrodou, která má téměř nulový potenciál. U bipolárních svodů se měří napětí mezi dvěma měřicími elektrodami. Podle konvence platí, že v případě proudu, který směřuje od elektrody, je výchylka negativní, a v případě, že proud směřuje k elektrodě, je výchylka pozitivní. [4][5]

Nejčastěji je využíváno 12svodové EKG, které se skládá z tří typů svodů. Bipolární končetinové svody (I, II, III) tvořící tzv. Eithovenův trojúhelník, měří napětí mezi pravou a levou rukou a levou nohou, tedy rozdíl potenciálů mezi vrcholy Eithovenova trojúhelníku. Goldbergerovy unipolární svody (aVR, aVL, aVF) měří rozdíl potenciálu jednoho svodu vůči průměru zbývajících dvou. Unipolární hrudní svody (V1 až V6) měří potenciály na různých místech hrudníku. Napětí se měří vůči Wilsonově svorce, která vznikne zprůměrováním napětí končetinových svodů. [4][5]

Intrakardiální EKG zaznamenává srdeční elektrickou aktivitu pomocí katétrů zavedených přímo do srdce. Elektrody jsou zavedeny do srdce prostřednictvím žil. Na základě přesné lokalizace zdroje signálu pak tyto záznamy nesou vysokou diagnostickou informaci. Tento typ záznamů byl využit jako zdroj referenčního značení P vln v datech použitých v programu této práce. [7]

## 1.3 EKG křivka

V rámci jednoho srdečního cyklu lze pomocí EKG křivky pozorovat vlny, kmity a úseky mezi nimi, které nesou významnou informaci při diagnostice srdečních onemocnění. Sleduje se především amplituda a doba trvání jednotlivých vln. Fyziologický průběh křivky EKG znázorňuje Obrázek 1. [1]



Obrázek 1 - Normální průběh EKG s uvedenou délkou jednotlivých intervalů [ms]  
(převzato z [6])

Depolarizaci síní, která vzniká na základě vzruchu v SA uzlu odpovídá **vlna P**. Vlna P má v EKG křivce malou amplitudu, neboť svalová stěna síní je poměrně tenká. Po vlně P následuje **PQ interval**, který představuje převod vzruchu AV uzlem ze síní na komory. Depolarizaci komor pak na EKG křivce odpovídá **QRS komplex**, který nese značnou amplitudu, neboť svalovina komor je mohutná. Po depolarizaci komor jsou srdeční vlákna v tzv. fázi plató, během které je prodloužena refrakternita buněk. Tomu v EKG křivce odpovídá **ST úsek**. Repolarizaci komor odpovídá **T vlna**. **QT úsek** představuje dobu trvání depolarizace a repolarizace komor. Po vlně T někdy následuje **vlna U** o malé amplitudě, která zatím nemá objasněný význam. [1][4][5]

Vzhledem k tomu, že tato práce se zabývá detekcí vlny P, v tomto odstavci je popsán průběh právě této vlny při fyziologických podmínkách a při různých patologiích. Amplituda fyziologické vlny P dosahuje maximálně 0,25 mV a trvá maximálně 0,10 s. Nejlépe je vlna P identifikovatelná ve svodech II a V1. Ve svodu aVR je vždy negativní a ve svodech III a V1 je negativní často. Ve svodu V1 často vlna P zaujímá bifazický průběh. Pokud je vlna P pozitivní ve všech svodech mimo III a V1 a je v pravidelných intervalech a pokud se za ní nachází QRS komplex, pak se jedná o sinusový rytmus. Pokud je vlna P ve svodech II, III, aVF nebo v hrudních svodech negativní, pak se pravděpodobně jedná o junkční rytmus. Vlna P chybí v případě fibrilace síní (Obrázek 2), flutteru síní, SA bloku, komorové a supraventrikulární tachyardií a při fibrilaci a flutteru komor. [1][9]





Obrázek 2 - Fibrilace síní (svod I). P vlna není přítomna (převzato z [1])


## 2. NEURONOVÉ SÍTĚ

Vzhledem k tomu, že tato práce si klade za cíl naimplementovat neuronovou síť pro segmentaci P vln, v této kapitole budou zmíněny obecné principy hlubokého učení a popsány jednotlivé typy vrstev neuronových sítí.

V současné době je neuronovým sítím věnována velká pozornost a jejich využití lze nalézt v několika oborech. Uplatnění nachází například v počítačovém vidění či zpracování signálů, kde se neuronové sítě využívají pro klasifikaci dat, regresní analýzu či shlukovou analýzu. [13]


### 2.1 Neuron

Základní koncept neuronových sítí je založen na analogii s nervovým systémem. Neuron, základní funkční jednotka nervové tkáně, se skládá z těla, dendritů a axonu. Dendrity šíří vzruch směrem do těla neuronu. Tělo neuronu zpracovává vstupní signály. Na základě velikosti stanoveného vnitřního potenciálu pak může dojít k excitaci neuronu. Axon pak vede výstupní signál k synapsím, které nasedají na ostatní neurony nebo jiné buňky. Obrázek 3 představuje stavbu neuronu. [10][12]



Obrázek 3 - Biologický neuron (převzato z [12])

Analogicky lze uvést, že umělá neuronová síť je tvořená matematickými neurony, které zpracovávají vstupní signály a generují výstup. Model neuronu je znázorněn na Obrázek 4 - Model neuronu (převzato z [11]) Písmeno  $x$  na obrázku představuje vstupní signál. Sílu synapsí představují váhy  $w$ . Vnitřní potenciál neuronu je označen  $\xi$ , práh  $h$ , aktivační přenosová funkce  $\sigma$ . Výstupní signál je označen písmenem  $y$ . [11]



Obrázek 4 - Model neuronu (převzato z [11])

Vnitřní potenciál neuronu lze vypočítat pomocí rovnice

$$\xi = \sum_{i=1}^n w_i \cdot x_i - h, \quad (1)$$

kde proměnné mají stejný význam jako v Obrázek 4 - Model neuronu (převzato z [11]). Každý vstupní prvek je tedy násoben příslušnou váhou. V těle neuronu jsou tyto hodnoty sečteny pro všechny prvky vektoru a od výsledku je odečtený práh. Výstupní hodnota je argumentem aktivační funkce. V praxi se ale práh často definuje jako váha na nulté pozici a vstupní vektor je na této pozici rozšířen o 1. Celkový výstup neuronu tak lze zapsat pomocí rovnice

$$y = \sigma(\xi) = \sigma\left(\sum_{i=0}^n w_i \cdot x_i\right), \quad (2)$$


kde  $x_0 = 1$  a  $w_0 = -h$ . [11]

Jednotlivé neurony jsou stavebními kameny neuronových sítí. Klasické dopředné sítě lze rozdělit na jednovrstvé a vícevrstvé neuronové sítě. Kromě nich existuje několik

dalších typů, příkladem mohou být rekurentní neuronové sítě, konvoluční neuronové sítě, sítě s radiální bází a Kohenovy samoorganizující se mapy. V této práci bude pozornost věnována především konvolučním neuronovým sítím.[10][11][14]

## 2.2 Jednoduchá neuronová síť

Neuronovou síť lze chápat jako váhovaný orientovaný graf, kde uzly zastupují matematické neurony. Existuje velké množství architektur neuronových sítí. Pro jednoduchost bude v této kapitole popsána jedna ze základních architektur a to dopředná neuronová síť, kde jsou neurony orientovány do vrstev. Pokud jsou jednotlivé neurony propejeny s neurony z předešlé vrstvy, mluvíme o plně propojené dopředné síti. První vrstva neuronové sítě se nazývá jako **vstupní vrstva**. Pomocí poslední vrstvy získáváme výstupy celé neuronové sítě, a proto se tato vrstva nazývá **výstupní**. Mezi těmito vrstvami se nachází **skryté vrstvy**. Pokud neuronové sítě obsahují velké množství skrytých vrstev, jedná se o tzv. hluboké neuronové sítě. Počet neuronů vstupní a výstupní vrstvy závisí na aplikaci řešené úlohy, počet skrytých vrstev pak na složitosti řešené úlohy. Obrázek 5 představuje plně propojenou dopřednou neuronovou síť. [10][11]




Obrázek 5 - Plně propojená dopředná neuronová síť (převzato a upraveno z [10])

## 2.3 Hyperparametry sítě


Hyperparametry neuronové sítě jsou takové parametry, které se během učení až na výjimky nemění. Správné nastavení těchto hyperparametrů má zásadní vliv na konečnou úspěšnost neuronové sítě. Mezi hyperparametry řadíme **počet epoch**, tedy kolikrát dojde k předložení všech vzorků z trénovací množiny neuronové síti. V případě, že počet epoch bude příliš nízký, neuronová síť se nestihne dostatečně naučit. Naopak, pokud bude počet epoch příliš vysoký, u neuronové sítě hrozí přeučení a síť ztratí schopnost generalizace (neuronová síť bude mít malou úspěšnost při nových testovacích datech). Často se proto volí předčasné ukončení učení při dostatečně dobrých výsledcích za účelem předejití přeučení neuronové sítě. [10][11]

Mezi další hyperparametry patří **krok učení** ( $LR = \text{learning rate}$ ). Tento hyperparametr má zásadní vliv na rychlost konvergence a na proces adaptace vah. Při použití příliš malého kroku učení je konvergence velmi pomalá. Tento případ znázorňuje Obrázek 6, kde  $f(x)$  je kritériální funkce, jejíž minimum má být nalezeno.



Obrázek 6 – Nalezení globálního minima při příliš malém kroku učení (převzato z [10])

Naopak při použití příliš velkého kroku učení hrozí „přeskočení“ globálního minima, jak znázorňuje Obrázek 7 - Příliš velký krok učení, vlevo: u konvexní účelové funkce, vpravo: u složitější účelové funkce.[10]




Obrázek 7 - Příliš velký krok učení, vlevo: u konvexní účelové funkce, vpravo: u složitější účelové funkce (převzato z [10])


Dalším hyperparametrem je tzv. **BatchSize** (velikost dávky), který stanovuje, po kolika vzorcích se neurová síť paralelně učí, tedy pro kolik vzorků se bude počítat hodnota kritériální funkce. Výhodou je především zrychlení učení a možnost paralelizace výpočtu. Při příliš malé dávce hrozí, že při klasifikačním problému nebudou obsaženy všechny třídy dat, při příliš velké dávce se zvyšuje výpočetní náročnost. [10][14]

## 2.4 Přenosová aktivační funkce

Existuje několik typů aktivačních přenosových funkcí. Použití jednotlivých typů závisí na řešeném problému. Obvykle je ale žádoucí, aby aktivační funkce byla diferencovatelná z důvodu využití učících algoritmů založených na gradientních metodách. Průběhy různých aktivačních funkcí znázorňují obrázky Obrázek 8 a Obrázek 9. [10][11][15]



Obrázek 8 - Přenosová aktivační funkce. Shora skoková funkce, po částech lineární funkce, logistická sigmoida (převzato a upraveno z [11])



Obrázek 9 - Přenosová aktivační funkce. Shora hyperbolický tangens, ReLU, leaky ReLU (převzato a upraveno z [15])

## 2.5 Princip učení

Jednotlivé neurony transformují vstupní vektor na hodnotu výstupní. Parametry, které nese neuron, musí být během učení vhodně modifikovány tak, aby neuron provedl požadovanou transformaci. Těmito parametry myslíme váhy a prahy, které představují jakousi paměť neuronu. Parametry jsou upravovány většinou iterativně. Obecně lze učení neuronových sítí rozdělit na **učení s učitelem** a **učení bez učitele**. Při učení bez učitele nemáme k dispozici správnost požadované transformace vstupních dat. Algoritmus tak hledá vnitřní souvislosti ve vstupních datech. V případě učení s učitelem máme k dispozici vždy dvojice prvků  $x$  a  $y_d$ , kde  $x$  je vstup a  $y_d$  požadovaný výstup řešené úlohy. Obvykle se data rozdělí na tři množiny – **trénovací**, **validační** a **testovací množinu**. Poměr rozdělení dat není pevně dán, je potřeba ho zvolit s ohledem na řešenou úlohu. Trénovací data jsou předkládány dopředné neuronové síti a po zjištění odchylky od požadovaného výstupu se provádí úprava parametrů neuronů. Chyba je v průběhu učení vyhodnocována i na validační množině za účelem zabránění přeučení sítě. Testovací množina pak slouží k vyhodnocení úspěšnosti sítě. Parametry neuronů jsou modifikovány na základě zvolených pravidel. Příkladem může být Hebbovou pravidlo, Delta pravidlo nebo gradientní optimalizace. [10][11]

## 2.6 Kriteriační funkce

Kriteriační funkce ohodnocuje kvalitu modelu, která se využívá při úpravě vah neuronů. Stanovuje, jak moc se predikovaný výsledek liší od požadovaného. Při učení modelu je cílem výstup kriteriační funkce minimalizovat. Na základě hodnoty kriteriační funkce se parametry sítě upravují pomocí algoritmu zpětného šíření chyby (viz kapitola 2.7). Tento algoritmus počítá parciální derivace kriteriační funkce individuálně pro každou váhu zvlášť. Na základě tohoto výpočtu se upraví velikost váhy proti směru gradientu. Iterativně se neuronové síti předkládají data z trénovací množiny a váhy sítě jsou postupně upravovány tak, aby hodnota kriteriační funkce byla minimalizována. Existuje několik typů kriteriačních funkcí. Pro regresní analýzu se využívá kriteriační funkce  $L_1$  a  $L_2$ , které definujeme jako

$$L_1 = \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (3)$$

$$L_2 = \sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (4)$$

kde  $y_i$  je  $i$ -tý požadovaný výstup z celkového počtu  $n$ ,  $\hat{y}_i$  je odhad  $i$ -tého vstupu.  
[11][16]

Při řešení klasifikačních úloh se často jako kritériální funkce volí **vzájemná entropie**. Pokud je zastoupení vzorků z jednotlivých tříd významně rozdílné, využívá se tzv. **váňované vzájemné entropie**, kterou lze vyjádřit vzorcem

$$L_{WCE} = - \sum_{c=1}^C \beta_c y_{i,c} \log(\hat{y}_{i,c}), \quad (5)$$

kde  $\beta_c$  je váha třídy  $c$ ,  $y_{i,c}$  je požadovaná hodnota třídy  $c$  pro  $i$ -tý vzorek,  $\hat{y}_{i,c}$  je predikovaná hodnota třídy se softmax aktivační funkcí pro  $i$ -tý vzorek a  $C$  je počet tříd.[16]

Další kritériální funkce, která se využívá v oblasti segmentace obrazů, je tzv. **Dice kritériální funkce**, která vychází z Dice koeficientu, jehož rovnici lze vyjádřit jako

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|}. \quad (6)$$

Úspěšnost segmentace je tak dána dvojnásobným počtem společných vysegmentovaných pixelů anotovaného obrazu  $X$  a výstupu sítě  $Y$  vydělený počtem všech vysegmentovaných pixelů v těchto obrazech. Rovnici Dice kritériální funkce lze pak zapsat jako




$$DL = 1 - \frac{2|X \cap Y| + 1}{|X| + |Y| + 1}, \quad (7)$$

kde číslo 1 se do čitatele a jmenovatele zlomku přidává pro případ, kdy  $|X| = |Y| = 0$ . [29]

## 2.7 Optimalizace

Učení neuronové sítě můžeme chápat jako optimalizační proces, kdy parametry sítě (váhy a prahy) upravujeme tak, abychom minimalizovali hodnotu kritériální funkce. Mezi základní optimalizační metody patří **metoda gradientního sestupu** ( $GD = Gradient Descent$ ). Při optimalizaci pomocí této metody se parametry sítě mění proti směru gradientu kritériální funkce. Zásadní vliv na výsledek má parametr  $LR$  (krok učení). Hlavní nevýhodou této metody je problém s uvíznutím v lokálním minimu. Parametry neuronové sítě jsou vždy upravovány až na konci epochy, tedy až po průchodu všech trénovacích dat. Princip této metody je znázorněn na Obrázek 10, kde  $J(\theta_l)$  je účelová funkce, u které je cílem nalézt globální minimum,  $\theta_l$  jsou parametry sítě. [10][14][15]



Obrázek 10 – Princip metody gradientního sestupu (převzato a upraveno z [18])

Existuje několik modifikací této základní gradientní metody. Mezi ně patří **metoda stochastického gradientního sestupu** ( $SGD = Stochastic Gradient Descent$ ), která nevyužívá přímý výpočet gradientu, ale gradient aproximuje pomocí náhodně vybraného prvku z učební množiny. Výhodou tohoto algoritmu oproti metodě GD je efektivnější učení z hlediska výpočetní náročnosti. Obdobu tohoto algoritmu je **Mini-Batch Gradient**

**Descent.** Ten k aproximaci gradientu využívá sadu několika náhodně vybraných vzorků z učební množiny dat. [10][15]

**SGD s hybností** (*SGD with Momentum*) je metoda, která algoritmus rozšiřuje o nové parametry hybnosti a rychlosti. Tato metoda při výpočtu bere v potaz gradienty z předešlých iterací. Pomocí těchto parametrů se posilují úpravy „směřující“ stejným směrem jako v předešlých krocích. [10][15][18]

Obdobou SGD s hybností je **Nesterovův adaptivní gradient** (*NAG = Nesterov Accelerated Gradient*), který při výpočtu nejdříve využije koeficient hybnosti a až poté koeficient rychlosti ve vypočteném bodě. [20]

**Adagrad** je metoda, která určuje učební krok pro každý parametr vah zvlášť. Obecně platí, že pro váhy s nízkým gradientem je učební krok zvýšen a naopak. [19]

Metoda **Adam** patří mezi jednu z nejpoužívanějších optimalizačních technik, neboť kombinuje již zmíněné optimalizační techniky, a tak přináší řadu výhod. Adam upravuje učební krok parametrů sítě na základě gradientů z předešlých kroků učení. U této metody je rychlost učení vůči každému parametru sítě adaptivní. K výpočtu se využívá průměrná hodnota exponenciálně zapomínaných gradientů z předchozích kroků a hyperparametry  $\beta_1$  a  $\beta_2$ . [19][20]

## 2.8 Regularizace vah

Váhová regularizace je jedna z metod, jak zamezit přeučení neuronové sítě. Přičtením regularizačního prvku k chybové funkci se zajistí pravidelnější distribuce vah. U **L1 regularizace** je přírůstek úměrný absolutní hodnotě váhových koeficientů a u **L2 regularizace** pak čtverci hodnot váhových koeficientů. [33]

## 2.9 Konvoluční neuronové sítě


V současné době konvoluční neuronové sítě dosahují velmi dobrých výsledků v oblastech zpracování obrazů, signálů, bioinformatice ale i v několika dalších oblastech. Existuje nespočet architektur konvolučních neuronových sítí. Základní stavební kameny těchto architektur však tvoří konvoluční, poolingové a plně propojené vrstvy.

### 2.9.1 Konvoluční vrstva

Konvoluční vrstva provádí operaci konvoluce, kde je výstupní vzorek dán váhovanou sumou vstupních vzorků, které jsou vymezeny konvoluční maskou (filtrem). Operace konvoluce je znázorněna pomocí rovnice

$$(f * g)(i) = \sum_a f(a)g(i - a), \quad (8)$$

kde  $*$  značí konvoluci,  $f$  je hodnota vzorku na pozici  $i$  a  $g$  je váha na této pozici. Hodnoty vah v konvoluční masce jsou předmětem učení sítě. Výstup konvoluční vrstvy se nazývá **příznaková mapa**. Obrázek 11 znázorňuje princip konvoluční vrstvy. [10][21]




Obrázek 11 – Konvoluční vrstva (převzato a upraveno z [21])

Na výstup této vrstvy je pak aplikována **aktivační funkce** (popsána v kapitole 2.4). Využívá se například sigmoida, hyperbolický tangens, ReLU a Leaky Relu.[22]

U konvolučních vrstev jsou důležité parametry **stride** a **zero-padding**. Parametr stride určuje, o kolik prvků se konvoluční maska bude posouvat po vstupní matici. Zero-padding pak říká, o kolik řádků a sloupců má být vstupní matice rozšířena nulami za účelem korigování velikosti výstupu.[10]

### 2.9.2 Poolingová vrstva

Za aktivační funkcí konvoluční vrstvy se většinou nachází poolingová vrstva. V určitých místech příznakové mapy dojde pomocí poolingové vrstvy k nahrazení těchto prvků jedním. Výstupem může být průměr prvků v daném okně (*average pooling*) nebo nalezené maximum (*max pooling*). Hlavní výhodou použití poolingových vrstev je snížení výpočetní náročnosti a zajištění prostorové invariance při malých posunech ve vstupní matici. Princip max-poolingu znázorňuje Obrázek 12 – Max pooling s oknem 2x2 a krokem 2 (převzato z [21])[10][21]




Obrázek 12 – Max pooling s oknem 2x2 a krokem 2 (převzato z [21])

### 2.9.3 BatchNorm vrstva

BatchNorm vrstva je vrstva, která normalizuje data před vstupem do další vrstvy neuronové sítě, čímž se předchází přeučení sítě a urychluje konvergenci algoritmu. Princip této vrstvy spočívá v normalizaci vstupních hodnot v rámci jednotlivých dávek. Nejčastěji se tato vrstva přidává mezi konvoluční vrstvu a vrstvu aktivační. Použití této vrstvy s sebou nese řadu výhod. Jde například o možnost nastavení vyšší hodnoty učebního kroku, nižší citlivost sítě k nastavení počátečních parametrů a již zmíněná rychlejší konvergence.[10][23]

### 2.9.4 DropOut vrstva

DropOut vrstva je regularizační vrstva, jejíž podstata spočívá v náhodném vypínání určitého procenta neuronů, čímž se zabráňuje přeučení sítě (viz Obrázek 13).[10]



Obrázek 13 - Princip DropOut vrstvy. Vlevo: před, vpravo: po vypnutí části neuronů (převzato a upraveno z [10])

## 2.10 Rekurentní neuronové sítě

Neuronové sítě doposud zmiňované tvořily vždy tzv. acyklický graf, kdy předchozí vstupy nijak neovlivňují vstupy následující. Existují však i takové neuronové sítě, které kopírují výstup skrytých neuronů vypočtených pro předcházející vstup. Tyto sítě se zpětnými vazbami nazýváme rekurentními neuronovými sítěmi. Rekurentní neuronové sítě se využívají například ve strojových překladech nebo pro generování textu. Mezi

hlavní výhodou těchto sítí patří možnost pracovat s vstupními posloupnostmi o různých délkách. [35][36]

Nejjednodušší rekurentní neuronovou síť by mohla být popsána pomocí jednoho vstupu a výstupu a jednoho neuronu ve skryté vrstvě. Rekurentní spojení bude tak neuron vykazovat sám do sebe. Během předložení nového vstupu neuron zkopíruje i aktivaci z předcházejícího vstupu. U složitějších rekurentních sítí pak váhy kopírují stav z předešlého časového kroku. Při trénování rekurentních neuronových sítí hrozí z principu způsobu učení dva problémy – explodující gradienty nebo mizející gradienty. Tyto problémy částečně řeší *Echo state sítě* a *LSTM sítě* (Long short term memory).[36]

## LSTM

LSTM sítě jsou tvořeny tzv. buňkami. Každá buňka pracuje se svou pamětí. Rekurentní vazby se nachází mezi jednotlivými buňkami. Vstup každé buňky tvoří její stav  $c_{t-1}$  z předchozího kroku a spojení výstupů z předchozího kroku a nových vstupů  $[h_{t-1}, x_t]$ . Buňku zobrazuje Obrázek 14. Hodnoty tvz. zapomínajících a vstupních bran se vypočítají jako

$$f_t = \alpha(W_f[h_{t-1}, x_t] + b_f), \quad (9)$$

$$i_t = \alpha(W_i[h_{t-1}, x_t] + b_i), \quad (10)$$

kde  $W_f$ ,  $W_i$ ,  $b_f$ ,  $b_i$  představují váhy a prahy a  $\alpha$  je aktivační funkce. Kandidát na nový vnitřní stav se vypočítá jako

$$\bar{c}_t = \alpha(W_c[h_{t-1}, x_t] + b_c), \quad (11)$$

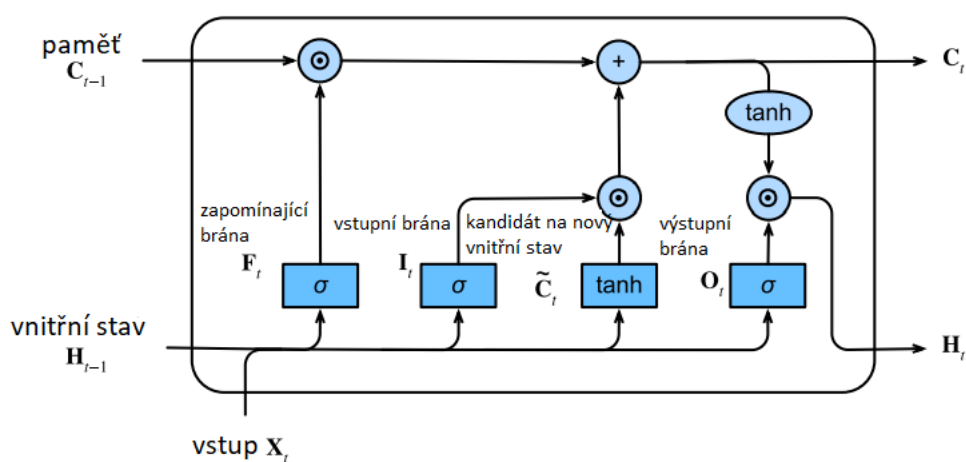
kde  $W_c$ ,  $b_c$  představují opět váhy a prahy pro výpočet stavu. Nový stav buňky získáme ze vzorce

$$C_t = f_t C_{t-1} + i_t \bar{C}_t. \quad (12)$$

Výstup buňky  $h_t$  se vypočítá z aktuálního stavu a vstupu pomocí tzv. výstupní brány (viz rovnice (13), (14)). Informace se tak přenáší mezi časovými kroky pomocí stavu, který není přímo spjat s žádnou váhou. Díky tomu LSTM síť předchází problémům s mizejícími či explodujícími gradienty. [36][37]

$$o_t = \alpha(W_o[h_{t-1}, x_t] + b_o), \quad (13)$$

$$h_t = o_t \alpha(C_t). \quad (14)$$



Obrázek 14 - Buňka LSTM sítě. Převzato z [10], upraveno.

### 3. METRIKY HODNOCENÍ KVALITY MODELU

Mezi základní metriky, které se využívají pro hodnocení kvality modelu patří **Accuracy** (přesnost). Tato metrika udává poměr správně zařazených vzorků vůči celkovému počtu vzorků, jak uvádí rovnice

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (15)$$

kde  $TP$  značí počet vzorků, které byly správně zařazeny jako vlna P.  $TN$  značí počet vzorků, které byly správně zařazeny do skupiny, kde se nejedná o P vlnu.  $FP$  značí nesprávně klasifikovanou P vlnu a  $FN$  značí počet vzorků, které byly nesprávně zařazeny do skupiny, ve které se nejedná o P vlnu. Tuto metriku však není vhodné používat na nevybalancovaných datech, kdy i při velmi špatné klasifikaci méně zastoupené třídy by metrika Accuracy dosáhla vysokých hodnot. Vzhledem k tomu, že v našem případě se jedná o nevybalancovaná data, bylo větší měrou přihlíženo k metrice **F1 skóre**. [28]

Pro výpočet F1 skóre je zapotřebí znát **senzitivitu** a **pozitivní prediktivní hodnotu** (PPH). Hodnota senzitivity značí schopnost modelu správně detekovat vlnu P, pokud je daný vzorek vlnou P ve skutečnosti. PPH vyjadřuje pravděpodobnost, že daný vzorek je vzorkem vlny P ve skutečnosti, pokud byl takto modelem zaklasifikován. Rovnice (16), (17) a (18) uvádějí výpočet těchto metrik, symboly v nich nesou stejný význam jako v předešlém odstavci. [27] [28]

$$senzitivita = \frac{TP}{TP + FN}, \quad (16)$$


$$PPH = \frac{TP}{TP + FP}, \quad (17)$$

$$F1\ skóre = \frac{2 \cdot senzitivita \cdot PPH}{senzitivita + PPH}. \quad (18)$$



## 4. POUŽITÁ DATA

K návrhu a testování programu bylo k dispozici celkem 100 záznamů ve formátu *json*. Jednotlivé záznamy obsahovaly 19svodové EKG o různých délkách o vzorkovací frekvenci 2000 Hz. Signály v záznamech již byly předzpracovány pomocí filtrů typu dolní a horní propust a Notch filtr za účelem potlačení nežádoucích frekvencí v signálech. Součástí záznamů byly i informace o lokalizaci jednotlivých P vln, přesněji tzv. *P-onset* (tedy začátek P vlny) a *P-offset* (konec P vlny) a informace o stanovené diagnóze. Zdrojem anotací P vln byla intrakardiální data. Cílem této práce byla detekce P vln na povrchovém 12svodovém EKG, intrakardiální EKG nebylo využito za účelem znesnadnění trénování neuronové sítě, neboť aktivitu síní na intrakardiálních datech lze velmi snadno pozorovat (viz Obrázek 15, kde aktivita síní je v intrakardiálním svodu CS5 mnohem lépe detekovatelná než v povrchovém svodu I).



Obrázek 15 – Srovnání povrchového a intrakardiálního záznamu EKG. Nahoře: EKG záznamy, dole: anotované P vlny.

Zastoupení stanovených diagnóz v záznamech shrnuje následující tabulka. Jednotlivé zkratky diagnóz jsou vysvětleny na konci práce.

Tabulka 1 – Přehled stanovených diagnóz u EKG záznamů

diagnóza	počet	diagnóza	počet
Sinusový rytmus	15	Sinusový rytmus , PAC	2
AVNRT	10	Sinusový rytmus , AVNRT, PAC	2
AVRT	8	FiS, WPW	2
Sinusový rytmus , WPW syndrom	7	Typický flutter síní, WPW	2
Sinusový rytmus , PVC	6	Sinusový rytmus , AVRT, PVC	2
Sinusový rytmus , junkční rytmus	4	Pace rytmus	2
Sinusový rytmus , FiS, WPW syndrom	4	fokální síňová tachykardie	2
Sinusový rytmus , WPW syndrom , PVC	3	FiS	1
AVNRT, LBBB	3	Sinusový rytmus , AVNRT, LBBB, PAC	1
Sinusový rytmus , AVRT	2	Pace rytmus, PAC, AVB3	1
FiS, fokální síňová tachykardie	1	Sinusový rytmus , junkční rytmus , PAC	1
Sinusový rytmus , AVNRT, PVC	1	Sinusový rytmus , PAC, PVC	1
Sinusový rytmus , AVRT, junkční rytmus	1	Sinusový rytmus , PVC, AVB1	1
Sinusový rytmus , FiS, PVC	1	Sinusový rytmus , LBBB	1
Sinusový rytmus , junkční rytmus , PVC	1	Sinusový rytmus , AVRT, WPW syndrom	1
Sinusový rytmus , fokální tachykardie, junkční rytmus	1	Sinusový rytmus , AVRT, FiS, WPW syndrom	1
Sinusový rytmus , AVRT, WPW syndrom , PVC	1	AVRT, FiS, WPW syndrom	1
Sinusový rytmus , FiS, Typický flutter síní	1	Sinusový rytmus , fokální síňová tachykardie	1
Sinusový rytmus , AVRT, WPW syndrom , PAC	1	AVRT, RBBB	1
Sinusový rytmus , AVNRT, LBBB	1	Sinusový rytmus , AVRT, PAC, PVC	1
Sinusový rytmus , RBBB	1		

## 5. NAVRŽENÝ PROGRAM

Program pro segmentaci P vln byl navržen v programovacím jazyce Python (verze 3.8.7 64-bit). V práci bylo využito několik knihoven. Následující tabulka shrnuje všechny využívané knihovny a jejich verze.

Tabulka 2 - Použité knihovny.

název knihovny	verze
os	3.8.7
json	2.0.9
scipy	1.5.0
numpy	1.18.5
pandas	1.0.5
matplotlib	3.2.2
sklearn	0.23.1
torch	1.7.0
random	3.8.7

V rámci praktické části byly vytvořeny celkem tři moduly. Modul s názvem *data\_preprocessing.py*, ve kterém jsou naimplementovány funkce pro předzpracování dat. Modul *models.py*, ve kterém je naimplementovaná architektura neuronové sítě (viz kapitola 5.2.1) a hlavní spouštěcí skript s názvem *main.py*.

### 5.1 Předzpracování dat

Počet dostupných vstupních dat ovlivňuje výslednou kvalitu modelu. Pokud totiž máme k dispozici malý dataset vzorků a implementovaný model obsahuje velký počet vstupních parametrů, pak hrozí tzv. *overfitting*, kdy model nemá žádnou schopnost generalizace (neuronová síť má velmi dobré výsledky na trénovací množině, ale výstupy pro validační a testovací množinu jsou slabé). [10][11]


Jedním ze způsobů, jak snížit riziko přeučení neuronové sítě při malém počtu vstupních dat, je umělé zvětšení datasetu neboli **augmentace**. V případě zpracování obrazů mezi základní augmentační transformace patří například posunutí, rotace, přiblížení nebo oddálení, rozmazání, zostření, přidání šumu nebo změna hodnot jasu, kontrastu a saturace. Pro 1D signály se využívá například zašumění, oříznutí signálu a roztažení signálu v x-ové nebo y-ové ose. Obecně je ale vždy nutné při výběru augmentačních technik brát ohled na datovou sadu, s kterou pracujeme.

Většina klasifikačních datasetů nemá pro jednotlivé třídy stejné zastoupení vzorků. Pokud je zastoupení tříd značně nerovnoměrné, je nutné na tento fakt brát ohled při vyhodnocování úspěšnosti sítě. Pokud bychom totiž využili jako vyhodnocovací

metriku *přesnost*, úspěšnost modelu by mohla být velmi vysoká i přes to, že neuronová síť predikuje pouze tu třídu, která má největší zastoupení. Proto je vhodnější pro vyhodnocení kvality modelu na nevyváženém datasetu využít metriky, jako je *f1 skóre*. [30][31]

**Kompenzaci imbalance dat** lze provést pomocí technik jako jsou *Random oversampling*, *Random undersampling* a *SMOTE*. Random oversampling je jednoduchá metoda, která vyváženosti datasetu docílí pomocí kopírování vzorků, jejichž třída je méně zastoupena. Naopak metoda Random undersampling dosáhne rovnoměrného zastoupení díky mazání vzorků, jejichž třída je nejpočetnější. Metoda SMOTE je oproti předchozím technikám o něco složitější. SMOTE metoda generuje nové syntetické vzorky na základě vlastností vzorků méně početné třídy. [30][31]


Data bylo nutné před vstupem do neuronové sítě vhodně předzpracovat. Pro každý signál z 12svodového EKG byl vytvořen binární signál na základě hodnot *P-onset* a *P-offset*, kde nuly představují vzorky, kde není přítomna P vlna a jedničky, kde vlna P přítomna je. Z dostupných záznamů bylo tedy získáno celkem 100 2D signálů z 12svodového EKG s příslušnými binárními reprezentacemi P vln. Celý proces předzpracování znázorňuje následující blokové schéma. Popis jednotlivých kroků je pak popsán v následujících podkapitolách.



Obrázek 16 - Blokové schéma předzpracování.

### 5.1.1 Podvzorkování

Za účelem snížení velikosti použitých dat při zachování maximálního množství informace byl každý signál společně s jeho příslušnou binární reprezentací přítomnosti P vln podvzorkován s faktorem 4. Vzorkovací frekvence signálů se tak změnila na 500 Hz. K tomu bylo využito funkce *decimate* z knihovny *Scipy*, která mimo samotného podvzorkování využívá i antialiasingový IIR Chebyshevův filtr. Vzhledem k tomu, že EKG signál má užitečné kmitočtové pásmo přibližně do 125Hz, decimací by nemělo dojít ke ztrátě užitečné informace. Příklad takto zpracovaných signálů znázorňuje Obrázek 17. Vizuální kontrolou nebyl zaznamenán žádný markantní rozdíl mezi signály, předpokládá se tak, že nedošlo ke ztrátě užitečné informace. [38]



Obrázek 17 - Původní EKG signál a signál po decimaci

### 5.1.2 Rozdělení dat do trénovací, validační a testovací množiny


Výhodou rozdělení dat do tří množin je především možnost v průběhu učení neuronové sítě vyhodnocovat kvalitu segmentace nejen na trénovací množině ale i na množině validační. Můžeme tak učení předčasně ukončit například při dosažení požadované kvality modelu nebo pro předejití přeučení neuronové sítě.

Data byla nejdříve náhodně rozdělena na trénovací a testovací množinu. Data byla rozdělena v poměru 8:2, kde trénovací množina obsahovala celkem 80 záznamů obsahujících 12svodové EKG signály, testovací množina pak 20 záznamů. Tento poměr byl zvolen s ohledem na fakt, že k dispozici bylo pouze 100 záznamů. V literárních pramenech ([24][26]), ze kterých byla převzata navržená architektura neuronové sítě však autoři využili datasety, které obsahovaly několik stovek záznamů EKG. Cílem tak bylo získat co největší trénovací množinu dat. Poměr 9:1 nebyl vybrán z důvodu příliš malého počtu záznamů v testovací a validační množině pro otestování kvality segmentace. Testovací množina byla následně rozdělena v poměru 1:1 na testovací (10 záznamů) a validační množinu (10 záznamů). K rozdělení záznamu do množin se využila funkce *train\_test\_split* z knihovny *sklearn.model\_selection*.

### 5.1.3 Augmentace trénovací množiny


Vzhledem k poměrně malé velikosti trénovací množiny byla provedena augmentace dat. Vliv augmentace dat na učení neuronové sítě ukazuje obrázek v následující kapitole. Za tímto účelem byly vytvořeny dvě funkce. První funkce s názvem *add\_noise*

implementovaná v modulu *data\_preprocessing.py* generuje Gaussovský šum, který se přičítá k původnímu signálu, jak ukazuje Obrázek 18. Vstupem funkce je 12svodové EKG, a hodnoty průměru a rozptylu Gaussovského šumu. Defaultně jsou tyto hodnoty nastaveny na 0 a 0,01.



Obrázek 18 - Signál před a po zašumění.

Druhá funkce s názvem *crop\_and\_scale* implementovaná ve stejném modulu jako funkce předchozí signál ořezává v x-ové ose a provádí roztažení signálu v y-ové ose. Vstupem funkce je 12svodové EKG. Pro roztažení signálu v y-ové se vygeneruje náhodné číslo v rozsahu od 0,8 po 1,2 a hodnoty signálu se s tímto číslem vynásobí. Pro oříznutí signálu v časové oblasti se generují dvě náhodná čísla. První číslo v rozsahu od 0 do 0,5 a druhé v rozsahu od 0,5 do 1. Po vynásobení původní délky signálu s čísly vygenerovanými se získají indexy pro začátek a konec nového signálu (viz Obrázek 19).




Obrázek 19 - Signál před a po oříznutí a roztažení v y-ové ose. Červené okno znázorňuje vybraný úsek.

Na každý signál z trénovací množiny byly postupně aplikovány tyto dvě funkce a následně kombinace obou dvou, čímž se trénovací sada zvětšila čtyřikrát (původní signál, zašuměný signál, oříznutý a roztažený signál v y-ové ose, zašuměný + oříznutý a roztažený signál v y-ové ose). Trénovací sada pak obsahovala 320 záznamů.

#### 5.1.4 Vytvoření datasetů a dataloaderů

Za účelem snadné manipulace s množinami signálů byly vytvořeny příslušné datasety a dataloadery. Dataset uchovává jednotlivé vzory a jejich příslušné výstupy. Dataloader k nim pak umožňuje snadný přístup a vytvoření tzv. *batchů* (dávek). Implementace vlastní třídy pro vytvoření datasetů se nachází v modulu *data\_preprocessing*. Tato třída dědí z *torch.utils.data.Dataset* a obsahuje metody s názvem `__len__` (pro získání velikosti datasetu) a `__getitem__` (pro získání vzoru a výstupu na daném indexu v datasetu). K vytvoření dataloaderů se využilo iterátoru *torch.utils.data.DataLoader*. Tento iterátor umožňuje promíchání pořadí dat při každé započaté epoše. Při tvorbě dataloaderů se též využilo parametru *collate\_fn*, který přesně definuje, jakým způsobem se vytvoří *batche*. Definice tvorby *batchů* je implementovaná pomocí třídy *Sequences\_padd*, která se též nachází v modulu *data\_preprocessing*. Pro každou dávku signálů (*batch*) bylo nutné jednotlivé signály v této dávce doplnit na stejnou délku. V dávce se proto signály doplnily hodnotami -1 na délku nejdelšího signálu v dané dávce, jak představuje Obrázek 20. K tomuto účelu se využila již zmíněná třída *Sequences\_padd*. Jednotlivé dávky obsahovaly 12svodové EKG signály doplněné na hodnotu nejdelšího signálu v dávce, příslušné výstupy, informace o původních délkách signálů a informace o stanovených diagnózách.






Obrázek 20 – EKG signál a jeho anotace doplněny hodnotami -1 na délku nejdelšího signálu v dávce

## 5.2 Architektura navržené neuronové sítě

Za účelem segmentace P vln byla na základě literatury [24], [25] a [26] implementována síť **U-Net** s vhodnými modifikacemi. Mezi hlavní výhody této neuronové sítě patří především malý počet parametrů neuronové sítě. Dle autorů odborného článku [24] tato neuronová síť dosahuje srovnatelných výsledků z hlediska kvality segmentace jako ostatní nejmodernější segmentační metody. Dokáže provést segmentaci EKG rychle a efektivně. Kvalita segmentace EKG dosahovala nejlepších výsledků ve srovnání s algoritmy využívající vlnkovou transformaci [39] či konvoluční neuronovou síť o 12 vrstvách [40].


U-Net je neuronová síť, která se hojně využívá v oblasti segmentace obrazů. Její název je odvozen od uspořádání vrstev, které připomíná písmeno U. Základní architekturu U-Net sítě představuje Obrázek 21. Tato síť se skládá ze dvou částí, první pro *downsampling* zastupující roli enkodéru, druhou pro *upsampling* zastupující roli dekodéru. Downsamplingová část přijímá vstupní obraz. Skládá se z několika konvolučních vrstev s Relu aktivací a maxpoolingovými vrstvami. Maxpoolingové vrstvy zmenšují velikost obrazu na polovinu. Počet filtrů se s rostoucí hloubkou sítě zvyšuje. Upsamplingová část obsahuje upsamplingové vrstvy, které postupně zvyšují rozlišení obrazu pomocí transponované konvoluce. Upsamplingová část využívá i zřetězení oříznutých map z downsamplingové části na odpovídající úrovni sítě za účelem zdokonalení převzorkování. Mezi nevýhody této architektury patří zejména požadavek na velikost vstupního obrazu, která musí být násobkem 16, neboť se využívá čtyř maxpoolingových vrstev s velikostí okna 2x2, takže dochází k postupnému zmenšování velikosti obrazu. [27]



Obrázek 21 - Základní zapojení sítě U-Net (převzato z [27])

### 5.2.1 Modifikace sítě U-Net

Za účelem segmentace P vln v EKG záznamech byla základní architektura U-Net modifikována pomocí pramenů [24], [25] a [26], kde autoři tuto architekturu využívají právě k segmentaci EKG. Obrázek 22 představuje neuronovou síť, která vedla k implementaci sítě pro segmentaci P vln.



Obrázek 22 - U-net pro segmentaci EKG, převzato z [24].

Mezi hlavní změny oproti původní implementaci sítě U-Net patří:

- využití 1D konvoluce místo 2D konvoluce
- snížení počtu kanálů v konvolučních vrstvách (viz Obrázek 21 a Obrázek 22)
- použití jiných parametrů vrstev (viz Tabulka 3)
- místo oříznutí map z downsamplingové části se využilo funkce *zero-padding* za účelem stejné velikosti výstupu a vstupu

### Naimplementovaná neuronová síť pro segmentaci P vln


Parametry vrstev a počet použitých kanálů v konvolučních vrstvách byly stanoveny na základě článku [24]. Bohužel autoři neuvádějí žádné faktické odůvodnění volby takto zvolených parametrů. Parametry shrnuje Tabulka 3. Krok u maxpoolingových vrstev byl nastaven na hodnotu 2. Vzhledem k tomu, že díky maxpoolingovým vrstvám se délka signálu vždy zmenší na polovinu, bylo nutné délku signálu ověřovat. Pokud totiž délka nebyla dělitelná dvěma beze zbytku, pak nebylo možné provést zřetězení map na daných úrovních sítě pro nestejnou velikost, neboť došlo díky zaokrouhlení k zkrácení signálu o jeden vzorek. Vzhledem k tomu, že v síti se využívají celkem 4 maxpoolingové vrstvy, se před samotným vstupem signálů do sítě ověřovala dělitelnost délky signálů číslem 16. V případě potřeby pak byly délky doplněny na požadovanou velikost pomocí implementované funkce s názvem *divisible\_by\_16* v modulu *data\_preprocessing.py*.

V článku [24] byly předkládány pouze 1D EKG signály z jednotlivých svodů. V našem případě se neuronové síti předkládaly signály z 12svodového EKG. Kanály EKG tak tvořily příznaky vstupního tensoru. 1D operátor pak počítal konvoluci přes všechny

příznaky a lokálně přes časovou osu v závislosti na velikosti okna filtru. Architekturu navržené neuronové sítě zobrazuje Obrázek 23. Kriteriaální funkci předcházela aktivační funkce typu sigmoida.

Tabulka 3 - Parametry vrstev sítě

	velikost filtru	zero-padding	stride
<b>konvoluční vrstvy</b>	9	4	1
<b>vrstvy pro transponovanou konvoluci</b>	8	2	3
<b>poslední konvoluční vrstva</b>	1	0	1



Obrázek 23-Naimplementovaná neuronová síť.

K implementaci neuronové sítě byla využita knihovna Pytorch. Naimplementovaný model s názvem *Unet* v modulu *models.py* dědí ze základní třídy *torch.nn.module*. Pomocí parametrizovaného konstruktoru této třídy se nastavují hodnoty dvou atributů. První atribut je pro nastavení počtu tříd v rámci segmentace (v našem případě nastaven na hodnotu 1). Druhý atribut pro zadání počtu příznaků vstupního tensoru (v našem případě 12). V konstruktoru jsou následně definovány jednotlivé vrstvy neuronové sítě s využitím hodnot atributů. Metoda třídy *Unet* s názvem *forward* přijímá vstupní tensor a definuje průchod neuronovou sítí vrstevami definovanými v konstruktoru. Počet a velikost filtrů pro jednotlivé vrstvy jsou znázorněny v Tabulka 3 a Obrázek 23. Za účelem minimalizování komplexity modelu byla vytvořena nová třída s názvem *Unet\_optim*. V této třídě byly počty a velikost filtrů různě modifikovány (viz dále). Konstruktore této

třídy oproti první třídě navíc obsahuje několik dalších atributů pro snadnější definování modelu pro různá nastavení. Atribut *config*, ve kterém jsou uloženy počty filtrů pro jednotlivé bloky sítě, *kernel\_size* definující velikost filtrů a *padding*, tedy o kolik sloupců má být tensor rozšířen nulami.


## 5.3 Trénování modelu

V této podkapitole jsou zobrazeny průběhy učení neuronové sítě pro různá nastavení hyperparametrů. Neuronová síť byla natrénována na trénovací množině. Současně s trénováním byla úspěšnost modelu ověřována na validační množině.


### 5.3.1 Výsledky pro intrakardiální signály

Za účelem ověření kvality segmentace byly neuronové síti nejdříve předloženy intrakardiální EKG záznamy, kde je aktivita síní velmi dobře pozorovatelná (viz Obrázek 15).


Pro první otestování sítě byly experimentálně zvoleny následující parametry. Učební krok byl nastaven na hodnotu 0,001. K optimalizaci byla vybrána metoda Adam. Jako kritériální funkce byla zvolena Dice kritériální funkce. Počet epoch byl experimentálně nastaven na hodnotu 30, parameter batch size na 10. Následující obrázky shrnují úspěšnost modelu na trénovacích a validačních datech.



Obrázek 24 - Průběh kritériální funkce během učení na trénovací a validační množině.



Obrázek 25 - Přesnost segmentace během učení na trénovací a validační množině pro intrakardiální data.



Obrázek 26 - Průběh F1 skóre během učení na trénovací a validační množině pro intrakardiální data.


Po dvacáté epoše přesnost na trénovacích a validačních datech přesahovala 96 %. F1 skóre dosahovalo pro trénovací množinu 93 %, pro validační pak 90 %. Po ověření dobré kvality segmentace na intrakardiálních datech byla neuronové síti předložena data z povrchového 12svodového EKG.

### 5.3.2 Výsledky pro 12svodové EKG

V této podkapitole jsou prezentovány výsledky neuronové sítě pro 12svodové EKG pro různá nastavení hyperparametrů neuronové sítě.

#### Vliv augmentace trénovací množiny

Vzhledem k tomu, že trénovací množina obsahovala poměrně malé množství dat, bylo vhodné množinu augmentovat. Způsob, jakým signály byly augmentovány popisuje kapitola 5.1.3. Z původních 80 signálů se tak trénovací množina zvětšila na 320 signálů. Zobrazení průběhu f1 skóre na validační množině znázorňuje následující obrázek.



Obrázek 27 - Průběh f1 skóre pro validační množinu před a po augmentaci.




Z grafu je zřejmé, že f1 skóre po augmentaci dosahovalo lepších hodnot. Maximální hodnota f1 skóre před augmentací byla 62 %, po augmentaci 70 %. Při zvětšení trénovací množiny na 640 signálů nedošlo k výraznému zlepšení průběhu f1 skóre, proto se pozůstalo u prvního způsobu augmentace.

### Nastavení parametrů neuronové sítě


Jako kriteriální funkce byla zvolena Dice kriteriální funkce. [31] K optimalizaci byla zvolena metoda Adam. Za účelem předejití přeučení byla trénovací množina augmentována a byla využita L2 regularizace.

### Krok učení


Krok učení byl experimentálně nastaven na hodnoty 0,1 a 0,001 a 0,00001. Následující obrázky zobrazují průběh kriteriální funkce na trénovací a validační množině pro různá nastavení kroku učení.



a) LR = 0,1



b) LR = 0,001



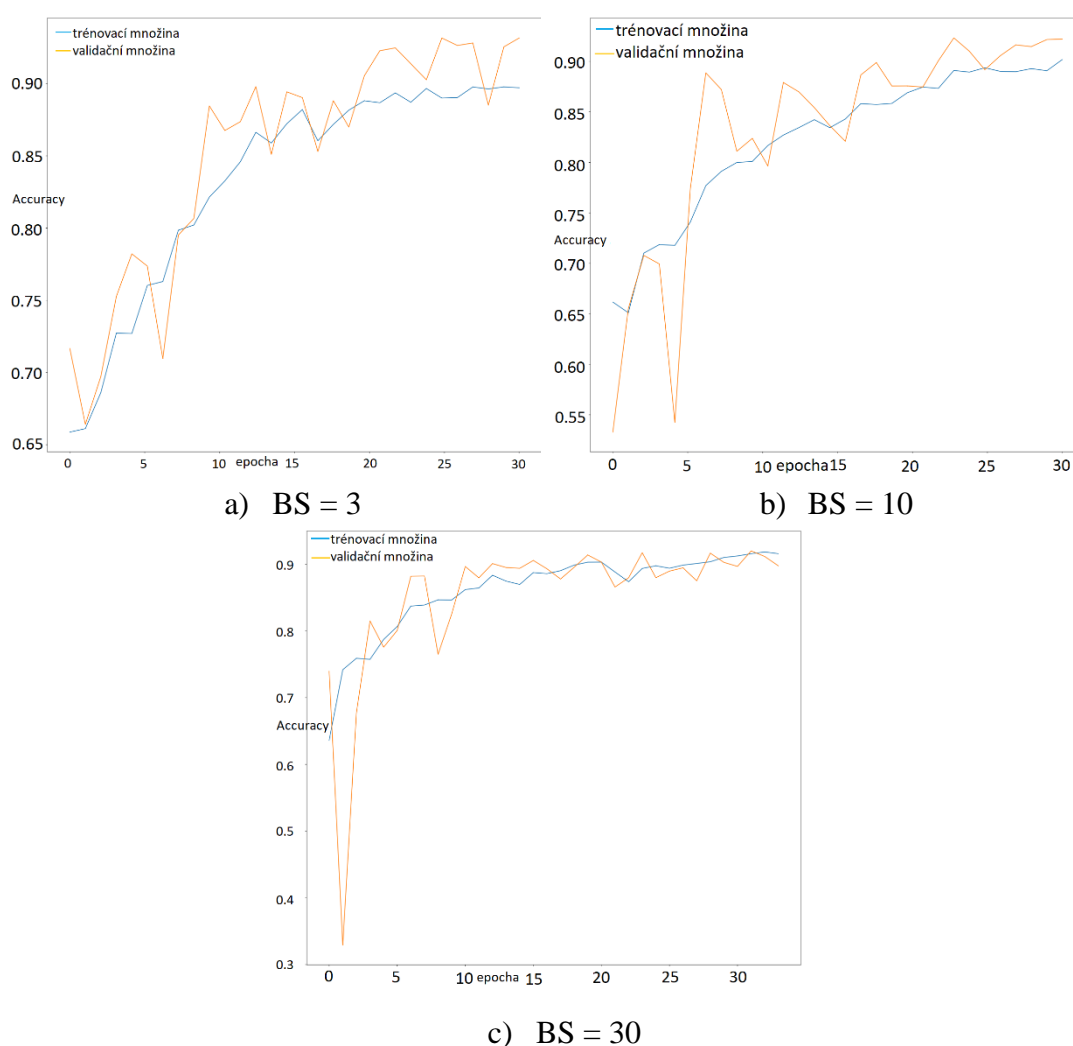
c) LR = 0,00001

Obrázek 28 - Průběh kriteriální funkce pro různá nastavení kroku

Z obrázků je zřejmé, že nejlepší průběh kritériální funkce byl pro  $LR=0,001$ . Pro toto nastavení vycházely i nejvyšší hodnoty přesnosti a f1 skóre. Pro  $LR=0,1$  nedocházelo k žádnému učení, neboť krok učení byl příliš velký a neprobíhala tak konvergence do lokálního či globálního minima.

### Batch size

Hyperparametr Batch size byl experimentálně nastaven na hodnoty 3, 10 a 30. Větší hodnoty Batch size nemohly být vyzkoušeny z důvodu nedostatečné paměti počítače. Následující obrázky představují průběh přesnosti pro různá nastavení tohoto parametru.




Obrázek 29 - Průběh přesnosti pro různá nastavení parametru Batch size.

Nejvyšší přesnost na validační množině byla pro *Batch size*=3, kdy hodnota dosahovala až 95 %. Pro toto nastavení vycházelo i nejvyšší *f1* skóre, které bylo po 30 epoše 75 %, pro ostatní nastavení se pohybovalo okolo okolo 70 %. Výhodou malé hodnoty *Batch size* je regularizační efekt, neboť zavádí šum, který napomůže „vyskočení“ z lokálního minima kritériální funkce. [40]


## 6. VÝSLEDKY

V této kapitole jsou zobrazen průběhy učení neuronové sítě pro finální nastavení hyperparametrů a pro optimalizovaný model. V závěru kapitoly jsou pak představeny EKG signály s anotovanými P vlnami v porovnání s výstupy neuronové sítě.

Pro nastavení  $BS=3$  a  $LR=0,001$ , který se po 50. epoše snížil o  $1/10$  dosahovala přesnost po 60. epoše 93 % pro trénovací i validační množinu a vykazovala celkem hladký průběh (viz Obrázek 30). F1 skóre bylo pro trénovací množinu 90% a pro validační se po 60. bylo 77 %. Dále hodnota již výrazně nestoupala, jak zobrazuje Obrázek 31. Pro testovací množinu byla přesnost 87 % a f1 skóre 63 %. F1 skóre pro testovací množinu vyšlo mnohem nižší jak pro množinu validační. Tento fakt byl způsoben zařazením obtížnějších signálů pro segmentaci P vlny do testovací množiny (viz konec této kapitoly).



Obrázek 30 - Průběh přesnosti pro trénovací a validační množinu.



Obrázek 31 - Průběh f1 skóre pro trénovací a validační množinu.

Následující tabulky zobrazují matice záměn pro trénovací, validační množinu a testovací množinu.

Tabulka 4 - Matice záměn pro trénovací, validační a testovací množinu.

trénovací množina			
		predikce	
		není vlna P	je vlna P
anotace	není vlna P	1442247	37271
	je vlna P	42451	338544

validační množina			
		predikce	
		není vlna P	je vlna P
anotace	není vlna P	45505	1809
	je vlna P	1520	5494

testovací množina			
		predikce	
		není vlna P	je vlna P
anotace	není vlna P	65315	5484
	je vlna P	5518	9211

Výsledné hodnoty f1 skóre a přesnosti se odvíjí od typů diagnóz rozdělených do trénovací, validační a testovací množiny. Výsledek kvality segmentace pro testovací množinu při spuštění programu s jiným rozdělením signálů v množinách znázorňuje následující obrázek. Výsledné f1 skóre pro testovací množinu bylo 85 %, přesnost 96 %. Značný rozdíl oproti původnímu f1 skóre (63 %) byl právě způsobený zařazením obtížnějších signálů do testovací množiny v původním případě.

```
['SinusRhythm rhythm WPW morphology', 'SinusRhythm rhythm JunctionalRhythm rhythm', 'AVNRT
rhythm', 'SinusRhythm rhythm FocalTachycardia rhythm JunctionalRhythm rhythm', 'AVNRT
rhythm', 'SinusRhythm rhythm WPW morphology PVC rhythm', 'SinusRhythm rhythm',
'SinusRhythm rhythm', 'SinusRhythm rhythm PVC rhythm', 'SinusRhythm rhythm']
CM test [[70350. 1923.]
[ 1448. 9724.]]
f1 test 0.8522722292826155
acc test 0.9596021331415903
```

Obrázek 32 - Výsledek pro jiné rozdělení signálů do množin. Shora: diagnózy signálů v testovací množině, matice záměn, f1 skóre, přesnost pro testovací množinu.

### Snížení komplexnosti neuronové sítě

Za účelem snížení komplexity modelu byly optimalizovány počet a velikost konvolučních filtrů. Původní model U-net v [24] se skládá z 5 bloků. Každý blok obsahuje 2 konvoluční vrstvy a počet filtrů v rámci bloků je dán následovně: 4-8-16-32-64 pro downsamplingovou část. Pro upsamplingovou část je dán počet filtrů stejnou řadou avšak sestupně seřazenou. Velikost filtrů pro všechny konvoluční vrstvy (s výjimkou poslední konvoluční vrstvy) je 9.


Cílem bylo snížit komplexitu modelu. Počet a velikost filtrů se tak různě modifikoval. Následující tabulka představuje vyzkoušené parametry. Při výběru počtu použitých filtrů se vždy bral ohled na skutečnost, že počet filtrů se s rostoucí hloubkou sítě zvyšuje. V následující tabulce sloupec Počet filtrů odpovídá hodnotám pro downsamplingovou část. Pro upsamplingová část byly počty definovány stejnou řadou sestupně.

Tabulka 5 – Optimalizace architektury

Počet filtrů	poznámka
4-8-16-32-64	původní architektura
2-4-8-16-32	počet filtrů v rámci bloku snížen na polovinu
4-8-16-20-32	pozměněn počet u posledních dvou bloků
2-4-8-32-64	pozměněn počet u prvních třech bloků
2-4-12-16-56	počty pozměněny u všech bloků
2-12-24-30-50	počty pozměněny u všech bloků
2-4-8-26-56	počty pozměněny u všech bloků


Celkem tak bylo definováno 6 modifikací architektury neuronové sítě. Pro každou modifikaci se navíc testovala kvalita segmentace pro dvě různá nastavení velikosti filtrů. Velikost filtrů (s výjimkou poslední konvoluční vrstvy) byla testována pro hodnoty 7 a 9, čímž vzniklo celkem 12 modifikací modelu. Trénování sítě probíhalo po dobu 20 epoch a sledovala se kvalita segmentace. Pokud křivka f1 skóre a přesnosti během učení vykazovala podobný průběh pro různé modifikace, upřednostnila se modifikace s celkovým menším počtem filtrů.

Velmi dobrý průběh f1 skóre a přesnosti vykazovalo nastavení počtu filtrů 2-4-12-16-56 a velikost filtrů 9. Pro tuto modifikaci byla neuronová síť natrénována po dobu 100 epoch. Následující obrázek představuje průběh f1 skóre pro trénovací a validaci množinu. F1 skóre v poslední epoše dosahovalo 89 % pro trénovací a 79 % pro validační množinu. Pro testovací množinu pak 64 %.



Obrázek 33 - Průběh f1 skóre pro trénovací a validační množinu.

Obdobně dobrých výsledků vykazovalo nastavení počtu filtrů 4-8-16-20-32 a velikost filtru 7. Průběh f1 skóre zobrazuje Obrázek 34 - Průběh f1 skóre pro trénovací a validační množinu. F1 skóre v poslední epoše dosahovalo 91% pro trénovací a 75% pro validační množinu. Pro testovací množinu bylo f1 skóre 60 %. Přesnost dosahovala obdobných hodnot jako v původním modelu.



Obrázek 34 - Průběh f1 skóre pro trénovací a validační množinu.


Původní architektura při vstupním tensoru o 12 příznacích obsahovala 23954017 parametrů, s využitím první modifikace popsané výše byl počet parametrů 12772225. Počet parametrů se tak snížil přibližně 2x. S využitím druhé modifikace byl počet parametrů 7053073 a snížil se tak přibližně 3x. Kvalita segmentace v obou případech byla zachována.

### 6.1.1 Zhodnocení kvality segmentace


V této podkapitole je zobrazeno několik EKG signálů s anotacemi P vln ve srovnání s výstupy navržené neuronové sítě s původním počtem a velikostí filtrů (viz Obrázek 23). V závěru jsou zobrazeny výstupy i pro optimalizovanou architekturu modelu.

Pro EKG signály obsahující **sinusový rytmus** bez jakékoliv patologie byla segmentace P vln velmi dobrá (viz Obrázek 36). Pro detailnější porovnání byla zobrazena segmentace pro jednu vlnu P. Výstup neuronové sítě se od anotace liší jen o několik vzorků, jak zobrazuje Obrázek 35.






Obrázek 35 - Porovnání anotace a výstupu neuronové sítě pro jednu P vlnu.




Obrázek 36 - Porovnání anotace a výstupu neuronové sítě. Shora: EKG signál, anotace P vln, výstup neuronové sítě.

Pro EKG signál obsahující **sinusový rytmus** a **WPW syndrom** projevující se především zkrácením PQ intervalu byly výsledky také velmi dobré. Všechny detekované P vlny se s anotacemi překrývaly z velké části. Výsledky ukazuje Obrázek 37.



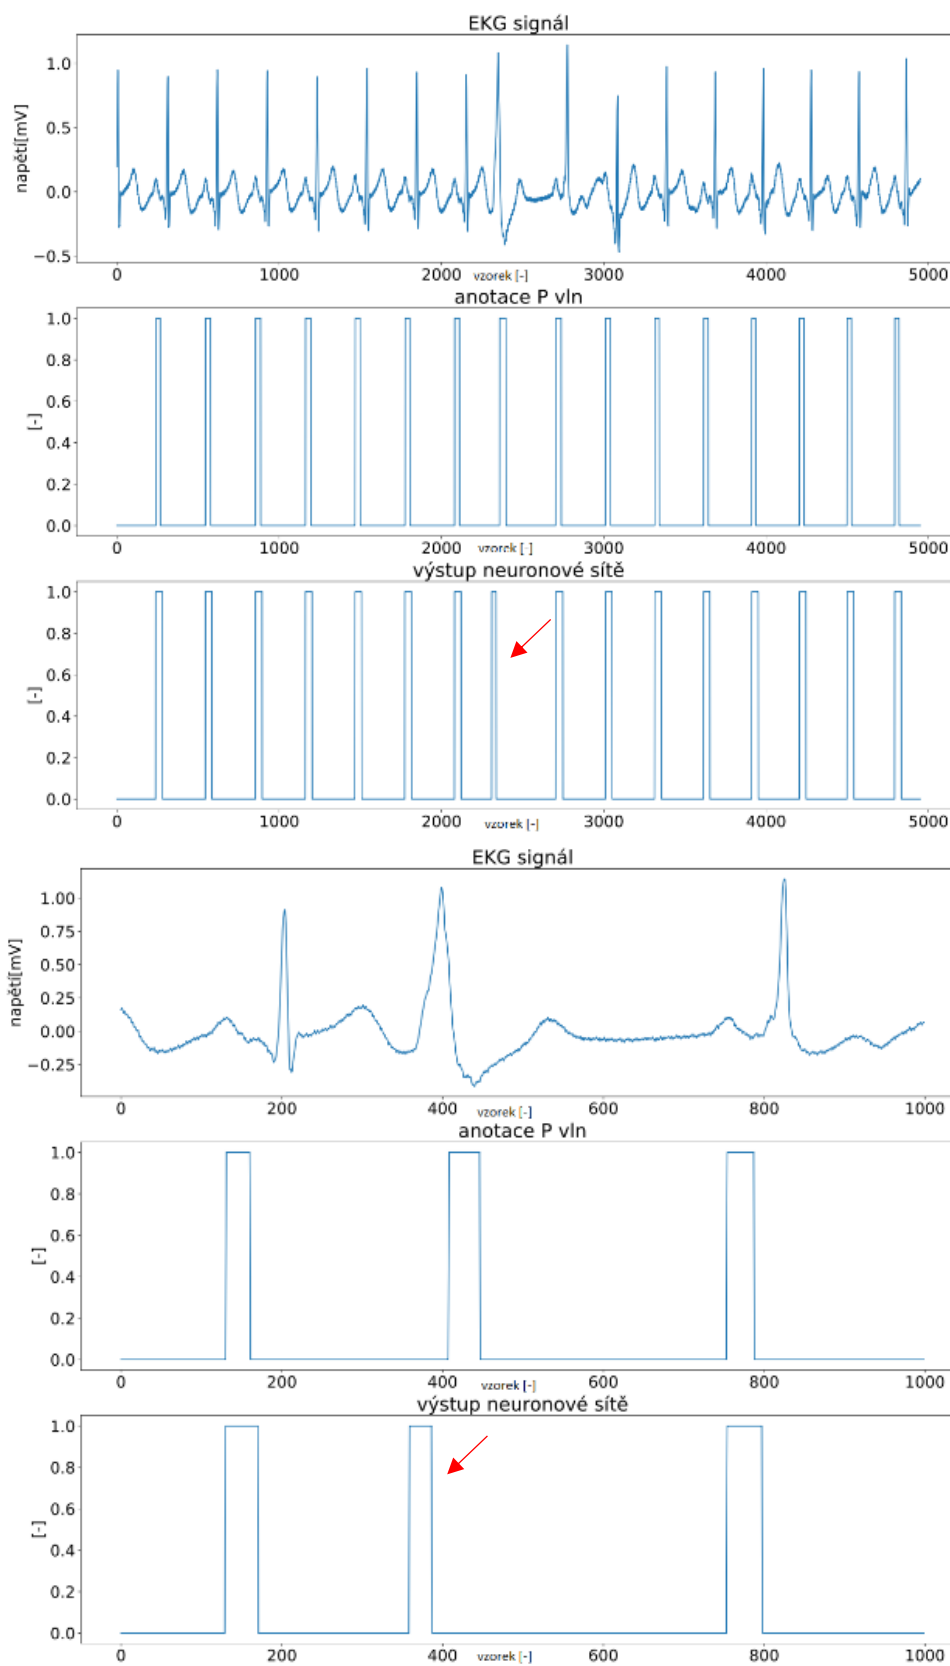
Obrázek 37 - Porovnání anotace a výstupu neuronové sítě.

Pro signál s diagnózou **sinusový rytmus**, **junkční rytmus** a **PAC** byly výsledky též uspokojivé. U junkčního rytmu může P vlna být před QRS komplexem, za QRS komplexem nebo skryta v QRS komplexu. I v části, kde EKG signál obsahoval junkční rytmus proběhla segmentace P vln dobře. Výsledky zobrazuje Obrázek 38. Šířka predikcí jednotlivých P vln byla o něco větší než anotace, avšak překryv mezi predikcí a anotací byl dostatečně velký.



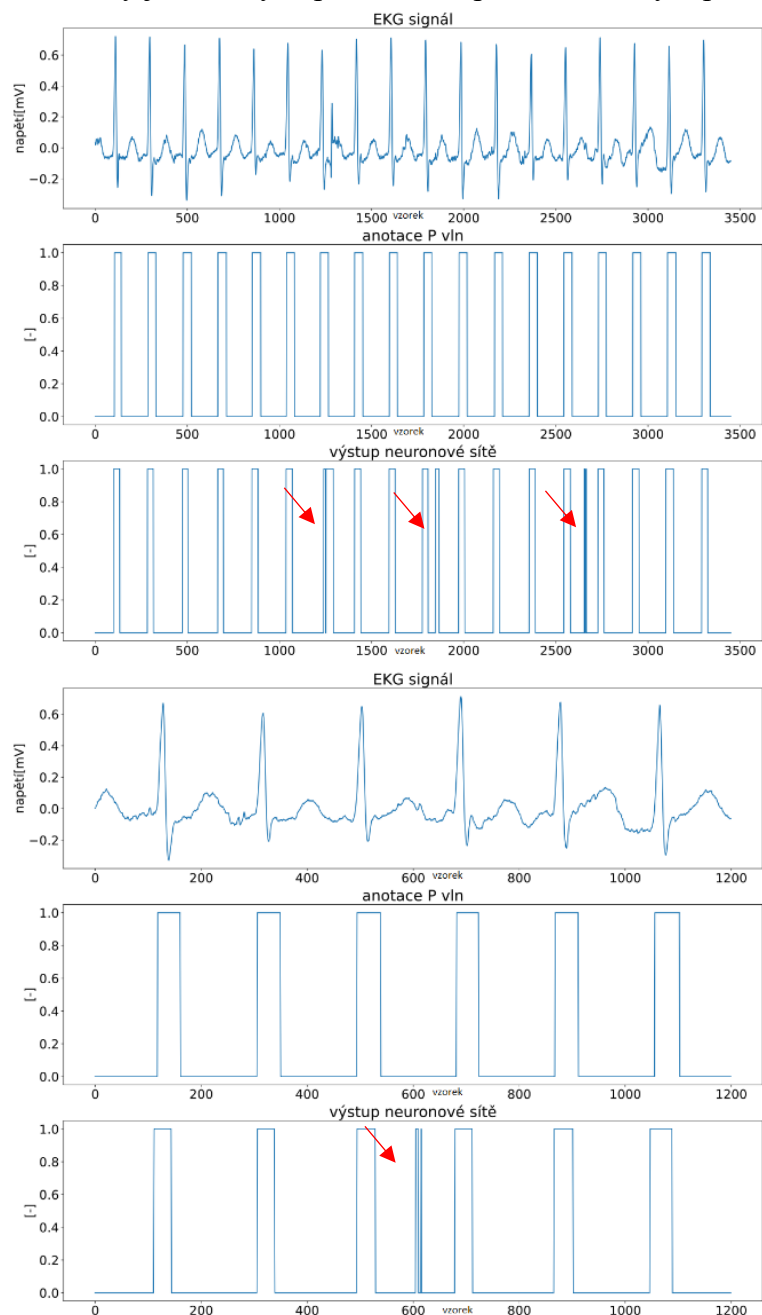
Obrázek 38 - Porovnání anotace a výstupu neuronové sítě.

U signálu s diagnózou **sinusový rytmus, WPW syndrom a předčasná komorová kontrakce (PVC)** neuronová síť nedokázala přesně detekovat P vlnu v oblasti PVC. Predikce předcházela anotaci, jak ukazuje červená šipka na následujících obrázcích.




Obrázek 39 - Porovnání anotace a výstupu neuronové sítě. Dole přiblížení na PVC.

**Atrioventrikulární nodální reentry tachykardie (AVNRT)** je porucha srdečního rytmu, jejíž projevem v EKG záznamech jsou pravidelné QRS komplexy, P vlny jsou skryty v QRS komplexu nebo jsou těsně za ním. I v případě takto skrytých P vln byla segmentace neuronovou sítí na poměrně vysoké úrovni, jak znázorňuje následující obrázek. Predikované P vlny se z velké části překrývaly s anotacemi. V signálu však vznikly 3 úzké predikce P vln, které ale žádné P vlně neodpovídaly. V obrázcích jsou opět označeny červenými šipkami. Tyto falešně pozitivní vzorky by však šlo lehce odstranit kontrolou šířky jednotlivých predikcí se správně zvoleným prahem.



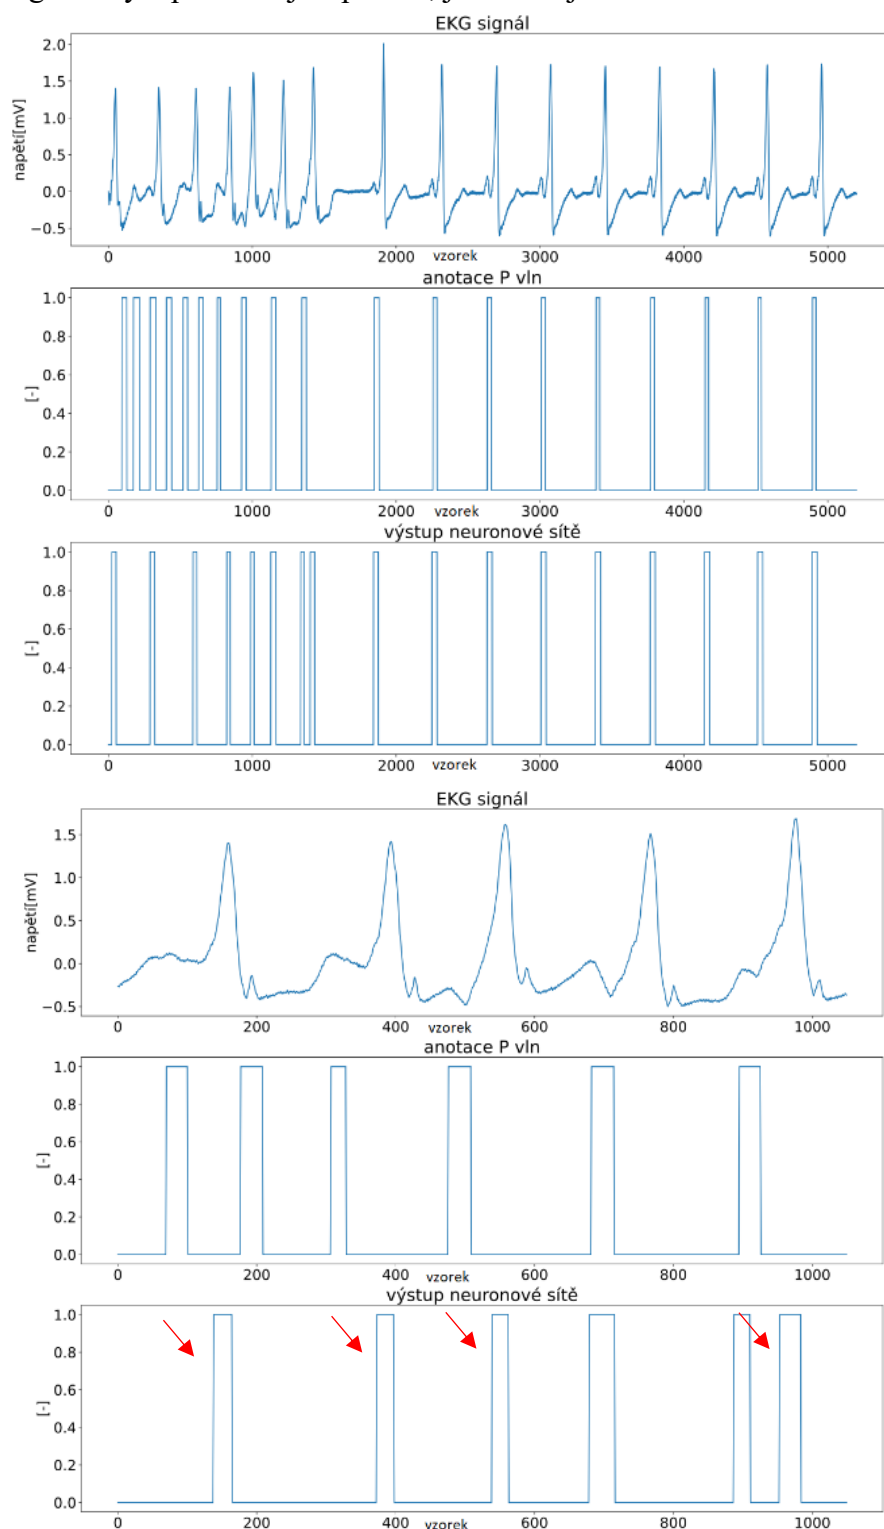
Obrázek 40 - Porovnání anotace a výstupu neuronové sítě. Dole v přiblížení.

**Fokální síňová tachykardie** se vyznačuje abnormálním tvarem P vln. I pro tuto diagnózu neuronová síť detekovala P vlny správně. Výsledky shrnuje Obrázek 41.




Obrázek 41 - Porovnání anotace a výstupu neuronové sítě. Dole v přiblížení.

Pro signál obsahující diagnózu **fibrilace síní**, **sinusový rytmus** a **WPW syndrom** neuronová síť selhala. V oblasti fibrilace predikovala nesmyslené pozice P vln. V druhé polovině signálu byla predikce již správná, jak ukazuje Obrázek 42.



Obrázek 42 - Porovnání anotace a výstupu neuronové sítě. Dole přiblížení na FIS.

Mezi další záznamy, u kterých neuronová síť selhala, patří signál s diagnózou **AVNRT**, **LBBB** a **PAC**. V podstatě po celé délce signálu neuronová síť predikovala nesmyslně, viz Obrázek 43.



Obrázek 43 - Porovnání anotace a výstupu neuronové sítě.


Pro dosažení lepších výsledků by nejspíše bylo vhodné rozšířit trénovací dataset o nové EKG signály. Jak ukazuje Tabulka 1, dostupný dataset obsahuje několik různých diagnóz, jejichž jednotlivá zastopení v celém datasetu jsou poměrně malá. Při náhodném rozdělování signálů do datasetů se tak může stát, že testovací množina obsahuje signály s diagnózou, která není přítomna v trénovací množině, detekce P vlny na takovýchto signálech pak může být obtížná.

#### **Ukázka výsledků pro optimalizovaný model:**

V této podkapitole je zobrazeno několik výsledků pro optimalizovaný model s nastavením počtu filtrů 2-4-12-16-56 a velikost filtrů 9.


Segmentace u signálu s diagnózou **sinusový rytmus**, **WPW syndrom** byla na dobré úrovni, jak ukazuje Obrázek 44.






Obrázek 44 - Porovnání anotace a výstupu optimalizované neuronové sítě.

Stejně obstojná byla segmentace u signálu s diagnózou **fokální síňová tachykardie** (viz Obrázek 45).




Obrázek 45 - Porovnání anotace a výstupu optimalizované neuronové sítě.

Příklad, kde optimalizovaná neuronová síť selhala, zobrazují následující obrázky. U první signálu s diagnózou **sinusový rytmus**, **FIS**, **WPW syndrom** byla segmentace nesmyslná v první polovině signálu.



Obrázek 46 - Porovnání anotace a výstupu optimalizované neuronové sítě.

Pro signál se stanovenou diagnózou **sinusový rytmus**, **AVNRT**, **LBBB**, **PAC** predikovala síť v rámci celého signálu špatně (viz Obrázek 47).



Obrázek 47 - Porovnání anotace a výstupu optimalizované neuronové sítě.

## 7. ZÁVĚR

Diplomová práce si kladla za cíl naimplementovat neuronovou síť za účelem segmentace P vln v EKG záznamech. V prvním segmentu teoretické části byla popsána fyziologie srdce a EKG. Poté byly popsány základní principy hlubokého učení. Pozornost byla věnována především konvolučním neuronovým sítím. Praktická část diplomové práce se věnovala implementaci neuronové sítě pro segmentaci P vln v programovém jazyce Python.

K dispozici bylo celkem 100 záznamů 19svodového EKG s příslušnými pozicemi začátku a konce jednotlivých P vln (tzv. *P onset* a *P offset*). Záznamy obsahovaly i informace o stanovené diagnóze a byly již předzpracovány pomocí filtrů typu dolní a horní propust a Notch filtr za účelem potlačení nežádoucích frekvencí v signálech. EKG záznamy nabývaly různých délek. Intrakardiální záznamy byly zdrojem anotací pozic P vln. Na základě těchto pozic byly vytvořeny binární reprezentace P vln, kde hodnoty 1 značí P vlnu, hodnoty 0 nepřítomnost P vlny. EKG signály společně s příslušnými binárními reprezentacemi P vln byly podvzorkovány z původní vzorkovací frekvence 2000Hz na 500Hz za účelem snížení velikosti použitých dat při zachování maximálního množství informace. Data následně byla náhodně rozdělena na trénovací a testovací množinu v poměru 8:2. Testovací data se poté rozdělila v poměru 1:1 na testovací a validační množinu. Trénovací množina tak obsahovala 80 signálů, validační 10 signálů a testovací též 10 signálů. Vzhledem k poměrně nízkému počtu signálů v trénovací množině byla data augmentována. K tomu byly vytvořeny dvě funkce, které jsou popsány v kapitole 5.1.3. Trénovací množina se tak zvětšila na 320 signálů. Za účelem snadnější manipulace s množinami signálů byly vytvořeny příslušné dataloadery, kde pro každou dávku signálů bylo nutné jednotlivé signály doplnit na délku nejdelšího signálu v dané dávce.

Následně byla naimplementována neuronová síť U-Net. Základní architektura sítě U-Net byla modifikována za účelem segmentace P vln v EKG záznamech pomocí pramenů [24], [25] a [26]. K optimalizaci učení sítě byla využita metoda Adam. Jako kritériální funkce byla zvolena Dice kritériální funkce. Funkčnost implementované sítě byla nejdříve ověřena na intrakardiálních datech, kde je aktivita síní velmi dobře pozorovatelná. Po dvacáté epoše přesnost na trénovacích datech a validačních datech přesahovala 96 %. F1 skóre dosahovalo pro trénovací množinu 93 %, pro validační pak 90 %. Po ověření dobré kvality segmentace se testovala úspěšnost sítě na 12svodovém EKG. Pro nejlepší výsledky segmentace bylo otestováno několik různých hodnot hyperparametrů neuronové sítě. Výsledná přesnost pro trénovací množinu byla 93 %, f1 skóre pak 90%. Pro validační množinu 93 %, respektive 77 %. Pro testovací množinu 87 %, respektive 63 %. Následně za účelem snížení complexity modelu byly modifikovány počty a velikost konvolučních filtrů. Pro modifikovanou architekturu výsledná přesnost a f1 skóre pro

trénovací množinu byla 95 % a 89 %, pro validační množinu 94 % a 79 % a pro testovací množinu 87 % a 64 %.

Následně byly zobrazeny výstupy jak původní neuronové sítě tak i optimalizované sítě v porovnání s příslušnými EKG záznamy a anotacemi P vln. Pro EKG signály obsahující sinusový rytmus byla kvalita segmentace na velmi dobré úrovni, stejně tak pro několik dalších patologií. Například pro atrioventrikulární nodální reentry tachykardii, kde je P vlna často skrytá v QRS komplexu, byla segmentace uspokojivá. V této kapitole je také zobrazeno několik signálu, u kterých neuronová síť nedokázala detekovat P vlny správně. Pravděpodobný důvod selhání neuronové sítě na těchto signálech je popsán v této kapitole 6.1.1.

## Literatura

- [1] GUYTON, Arthur C. a John E. HALL. *Textbook of medical physiology*. 10th ed. Philadelphia: Saunders, c2000. ISBN 0-7216-8677-X.
- [2] ČIHÁK, Radomír. *Anatomie 3*. 3., uprav. a dopln. vyd. Praha: Grada Publishing, 2016. ISBN 978-80-247-5636-3.
- [3] SEDMERA, David a František VOSTÁREK. Moderní pohled na převodní systém srdeční. *ČASOPIS LÉKAŘŮ ČESKÝCH*. 2017, 417-420. ISSN 1805-4420.
- [4] HAMPTON, John R. *EKG v praxi*. Vyd. 4. čes. Praha: Grada, 2007. ISBN 978-80-247-1448-6.
- [5] HAMPTON, John R. *EKG stručně, jasně, přehledně*. Praha: Grada, 2013. ISBN 978-80-247-4246-5.
- [6] HABERL, Ralph. *EKG do kapsy*. Praha: Grada, 2012. ISBN 978-80-247-4192-5.
- [7] ZANON, Francesco, Lina MARCANTONI, Gianni PASTORE, et al. Basic Properties And Clinical Applications Of The Intracardiac. *Journal of Atrial Fibrillation* [online]. 2016, 9(4) [cit. 2021-01-05]. ISSN 1941-6911. Dostupné z: doi:10.4022/jafib.1444
- [8] KOČÁREK, Eduard. *Biologie člověka 1*. 1. Praha: SCIENTIA, 2010. ISBN 978-80-8690-47-0.
- [9] HAMAN, MUDr. Petr. Výukový web EKG. In: Výukový web EKG [online]. Plzeň. Dostupné z: <http://ekg.kvalitne.cz/>
- [10] ZHANG, Aston, Zack C. LIPTON, Mu LI a Alex J. SMOLS. *Dive into Deep Learning* [online]. 0.15.1. 2020 [cit. 2021-01-05]. Dostupné z: <https://d2l.ai/d2l-en.pdf>
- [11] *Matematická biologie a biomedicína* [online]. Brno: Institut biostatistiky a analýz LF MU [cit. 2021-01-05]. Dostupné z: <https://www.matematickabiologie.cz/index.php>
- [12] VONDRÁK, Ivo. *Neuronové sítě* [online]. 1. Ostrava, 2009 [cit. 2021-01-05]. ISBN 80-7078-259-5. Dostupné z: [http://vondrak.cs.vsb.cz/download/Neuronove\\_site.pdf](http://vondrak.cs.vsb.cz/download/Neuronove_site.pdf)

- [13] ULDRICH, Miloš a Tomáš JURCZYK. *Neuronové sítě a jejich využití* [online]. 2014, , 1-2 [cit. 2021-01-05]. Dostupné z: [http://www.statsoft.cz/file1/PDF/Statsoft\\_neuronove\\_site.pdf](http://www.statsoft.cz/file1/PDF/Statsoft_neuronove_site.pdf)
- [14] HAGAN, Martin T. *Neural Network Design* [online]. 2. Oklahoma State University, 2014 [cit. 2021-01-05]. ISBN 978-0-9717321-1-7. Dostupné z: <https://hagan.okstate.edu/NNDesign.pdf>
- [15] URBAN, Sebastian. *Neural Network Architectures and Activation Functions: A Gaussian Process Approach* [online]. Mnichov: Technical University Munich, 2017 [cit. 2021-01-05]. Dostupné z: <http://mediatum.ub.tum.de/doc/1402689/106621.pdf>
- [16] JAKUBÍČEK, Roman. *METODY SEGMENTACE A IDENTIFIKACE DEFORMOVANÝCH OBRATLŮ VE 3D CT DATECH ONKOLOGICKÝCH PACIENTŮ* [online]. Brno, 2019 [cit. 2021-01-05]. Dostupné z: [https://www.vutbr.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=203602](https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=203602). DISERTAČNÍ PRÁCE. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, Fakulta elektrotechniky a komunikačních technologií. Vedoucí práce Prof. Ing. Jiří Jan, CSc.
- [17] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep Learning* [online]. MIT Press, 2016 [cit. 2021-01-05]. Dostupné z: <https://www.deeplearningbook.org/>
- [18] 5 Concepts You Should Know About Gradient Descent and Cost Function. *KDnuggets* [online]. 2020 [cit. 2021-01-05]. Dostupné z: <https://www.kdnuggets.com/2020/05/5-concepts-gradient-descent-cost-function.html>
- [19] KUMAR, Raunak. *Adagrad, Adam and Online-to-Batch* [online]. In: . British Columbia: University of British Columbia, 2017, s. 1-51 [cit. 2021-01-05]. Dostupné z: [https://raunakkmr.github.io/files/mlrg\\_2017\\_summer.pdf](https://raunakkmr.github.io/files/mlrg_2017_summer.pdf)
- [20] *METODY DETEKCE, SEGMENTACE A KLASIFIKACE OBTÍŽNĚ DEFINOVATELNÝCH KOSTNÍCH NÁDOROVÝCH LÉZÍ VE 3D CT DATECH* [online]. Brno, 2020 [cit. 2021-01-05]. Dostupné z: [https://www.vutbr.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=203600](https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=203600). DISERTAČNÍ PRÁCE. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, Fakulta elektrotechniky a komunikačních technologií. Vedoucí práce Prof. Ing. Jiří Jan, CSc.

- [21] PODAREANU, Damian, Valeriu Bogdan CODREANU a Sandra AIGNER. *Best Practice Guide - Deep Learning* [online]. 2019 [cit. 2021-01-05]. Dostupné z: doi:10.13140/RG.2.2.31564.05769
- [22] Wang, Y.; Li, Y.; Song, Y.; Rong, X. *The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition* [online]. 2020, , 1-20 [cit. 2021-01-05]. Dostupné z: <https://www.mdpi.com/2076-3417/10/5/1897#cite>
- [23] BJORCK, Johan, Carla GOMES, Bart SELMAN a Q. KILIAN. *Understanding Batch Normalization* [online]. Cornell University, 2018 [cit. 2021-01-05]. Dostupné z: <https://papers.nips.cc/paper/2018/file/36072923bfc3cf47745d704feb489480-Paper.pdf>
- [24] MOSKALENKO, Viktor, Nikolai ZOLOTYKH a Grigory OSIPOV. *Deep Learning for ECG Segmentation* [online]. Lobachevsky University of Nizhni Novgorod, Russia, 2020, , 1-10 [cit. 2021-01-05]. Dostupné z: <https://arxiv.org/abs/2001.04689>
- [25] G. Jimenez-Perez, A. Alcaine and O. Camara, "U-Net Architecture for the Automatic Detection and Delineation of the Electrocardiogram," 2019 Computing in Cardiology (CinC), Singapore, Singapore, 2019, pp. Page 1-Page 4, doi: 10.23919/CinC49843.2019.9005824.
- [26] SODMANN, Philipp a Marcus VOLLMER. *ECG Segmentation Using a Neural Network as the Basis for Detection of Cardiac Pathologies* [online]. 2020, , 1-4 [cit. 2021-01-05]. Dostupné z: [https://www.researchgate.net/publication/346279521\\_ECG\\_Segmentation\\_Using\\_a\\_Neural\\_Network\\_as\\_the\\_Basis\\_for\\_Detection\\_of\\_Cardiac\\_Pathologies](https://www.researchgate.net/publication/346279521_ECG_Segmentation_Using_a_Neural_Network_as_the_Basis_for_Detection_of_Cardiac_Pathologies)
- [27] RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX. *U-Net: Convolutional Networks for Biomedical Image Segmentation* [online]. Computer Science Department and BIOS Centre for Biological Signalling Studies, University of Freiburg, Germany, 2015, , 1-8 [cit. 2021-01-05]. Dostupné z: [https://www.researchgate.net/publication/346279521\\_ECG\\_Segmentation\\_Using\\_a\\_Neural\\_Network\\_as\\_the\\_Basis\\_for\\_Detection\\_of\\_Cardiac\\_Pathologies](https://www.researchgate.net/publication/346279521_ECG_Segmentation_Using_a_Neural_Network_as_the_Basis_for_Detection_of_Cardiac_Pathologies)



- [28] How to select Performance Metrics for Classification Models. *Medium* [online]. 2020 [cit. 2021-01-05]. Dostupné z: <https://medium.com/analytics-vidhya/how-to-select-performance-metrics-for-classification-models-c847fe6b1ea3>
- [29] JADON, Shruti. A survey of loss functions for semantic segmentation. *Electrical Engineering and Systems Science* [online]. 2020, , 2 [cit. 2021-01-05]. Dostupné z: doi:10.1109/CIBCB48159.2020.9277638
- [30] BROWNLEE, Jason. 8 Tactics to Combat Imbalanced Classes in Your Machine Learning Dataset. *Machine Learning Mastery* [online]. Vermont Victoria, Australia [cit. 2021-5-10]. Dostupné z: <https://machinelearningmastery.com/tactics-to-combat-imbalanced-classes-in-your-machine-learning-dataset/>
- [31] WU, Ye a Rick RADEWAGEN. 7 Techniques to Handle Imbalanced Data. *KDnuggets* [online]. [cit. 2021-5-10]. Dostupné z: <https://www.kdnuggets.com/2017/06/7-techniques-handle-imbalanced-data.html>
- [32] H. SUDRE, Carole, Li WENQI, Tom VERCAUTEREN, Sebastien OURSELIN a M. Jorge CARDOSO. *Generalised Dice overlap as a deep learning loss function for highly unbalanced segmentations* [online]. 2017, 1-8 [cit. 2021-5-10]. Dostupné z: doi:10.1007/978-3-319-67558-9\_28
- [33] CHOLLET, François. *Deep learning v jazyku Python: knihovny Keras, Tensorflow*. Přeložil Rudolf PECINOVSKÝ. Praha: Grada Publishing, 2019. Knihovna programátora (Grada). ISBN 978-80-247-3100-1.
- [34] FEIFEI, Liu, Liu CHENGY, Jiang XINGE, Zhang ZHIMIN, Zhang YATAO, Li JIANQING a Wei SHOUSHUI. Performance Analysis of Ten Common QRS Detectors on Different ECG Application Cases. *Hindawi, Journal of Healthcare Engineering* [online]. 1-9 [cit. 2021-5-10]. Dostupné z: <https://downloads.hindawi.com/journals/jhe/2018/9050812.pdf>
- [35] VENKATACHALAM, Mahendran. Recurrent Neural Networks. *Towards data science* [online]. 2019 [cit. 2021-5-10]. Dostupné z: <https://towardsdatascience.com/recurrent-neural-networks-d4642c9bc7ce>
- [36] PILÁT, Martin. Neuronové sítě - RBF sítě a rekurentní sítě. *Mgr. Martin Pilát, Ph.D.* [online]. Praha [cit. 2021-5-10]. Dostupné z:

<https://martinpilat.com/cs/prirodou-inspirovane-algoritmy/neuronove-site-rbf-site-rekurentni-site>

- [37] MITTAL, Aditi. Understanding RNN and LSTM. *Medium* [online]. [cit. 2021-5-10]. Dostupné z: <https://aditi-mittal.medium.com/understanding-rnn-and-lstm-f7cdf6dfc14e>
- [38] KOZUMPLÍK, Jiří. *Vlnkové transformace a jejich využití pro filtraci signálů EKG*. 2004. Habilitační práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ, ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ.
- [39] KALYAKULINA, Alena, Igor YUSIPOV, Victor MOSKALENKO a Alexander NIKOLSKIY. Finding morphology points of electrocardiographic signal waves using wavelet analysis. *ArXiv.org* [online]. 1-18 [cit. 2021-5-19]. Dostupné z: doi:10.1007/s11141-019-09929-2
- [40] SEREDA, Iana, Sergey ALEKSEEV a Aleksandra KONEVA. *ECG Segmentation by Neural Networks: Errors and Correction* [online]. , 1-7 [cit. 2021-5-19]. Dostupné z: <https://arxiv.org/pdf/1812.10386.pdf>
- [41] CHANG, Daryl. Effect of Batch Size on Neural Net Training. *Medium* [online]. [cit. 2021-5-19]. Dostupné z: <https://medium.com/deep-learning-experiments/effect-of-batch-size-on-neural-net-training-c5ae8516e57>

## SEZNAM SYMBOLŮ A ZKRATEK

Zkratky:

EKG	elektrokardiogram
GD	Gradient Descent
SGD	Stochastic Gradient Descent
NAG	Nesterov Accelerated Gradient
LR	Learning rate
PPH	pozitivní prediktivní hodnota
AVRT	atrioventrikulární reentry tachykardie
AVNRT	atrioventrikulární nodální reentry tachykardie
WPW syndrom	Wolffův-Parkinsonův-Whiteův syndrom
PVC	premature ventricular complex (komorové extrasystoly)
FiS	fibrilace síní
LBBB	left bundle branch block (blokáda levého Tawarova raménka)
RBBB	right bundle branch block (blokáda pravého Tawarova raménka)
PAC	premature atrial complex (síňové extrasystoly)
AVB	atriventrikulární blokáda